



Priscila Cristina Berbert Rampazzo

PLANEJAMENTO HIDRELÉTRICO:
OTIMIZAÇÃO MULTIOBJETIVO E ABORDAGENS EVOLUTIVAS

Campinas
2012

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

Priscila Cristina Berbert Rampazzo

PLANEJAMENTO HIDRELÉTRICO:
OTIMIZAÇÃO MULTIOBJETIVO E ABORDAGENS EVOLUTIVAS

Tese de doutorado apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Doutora em Engenharia Elétrica. Área de concentração: Automação.

Orientador: Prof. Dr. Akebo Yamakami

Co-Orientador: Prof. Dr. Fabricio Olivetti de França

Este exemplar corresponde à versão final da tese defendida pela aluna e orientada pelo Prof. Dr. Akebo Yamakami.

Campinas

2012

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

R147p Rampazzo, Priscila Cristina Berbert, 1984-
Planejamento hidrelétrico: otimização multiobjetivo e
abordagens evolutivas / Priscila Cristina Berbert
Rampazzo. --Campinas, SP: [s.n.], 2012.

Orientadores: Akebo Yamakami, Fabricio Olivetti de
França.

Tese de Doutorado - Universidade Estadual de
Campinas, Faculdade de Engenharia Elétrica e de
Computação.

1. Geração de energia. 2. Otimização multiobjetivo.
3. Computação evolutiva. 4. Algoritmos . 5. Usinas
hidrelétricas. I. Yamakami, Akebo, 1947-. II. França,
Fabricio Olivetti de. III. Universidade Estadual de
Campinas. Faculdade de Engenharia Elétrica e de
Computação. IV. Título.

Título em Inglês: Hydroelectric planning: multiobjective optimization and evolutionary
approaches

Palavras-chave em Inglês: Power generation, Multiobjective optimization,
Evolutionary computation, Algorithms, Hydroelectric power
plants

Área de concentração: Automação

Titulação: Doutora em Engenharia Elétrica

Banca examinadora: Ricardo Hiroshi Caldeira Takahashi, Erlon Cristian Finardi,
Secundino Soares Filho, Romis Ribeiro de Faissol Attux

Data da defesa: 19-10-2012





Programa de Pós Graduação: Engenharia Elétrica

COMISSÃO JULGADORA - TESE DE DOUTORADO

Candidata: Priscila Cristina Berbert

Data da Defesa: 19 de outubro de 2012

Título da Tese: "Planejamento Hidrelétrico: Otimização Multiobjetivo e Abordagens Evolutivas"

Prof. Dr. Akebo Yamakami (Presidente): 
Prof. Dr. Ricardo Hiroshi Caldeira Takahashi: 
Prof. Dr. Erlon Cristian Finardi: 
Prof. Dr. Secundino Soares Filho: 
Prof. Dr. Romis Ribeiro de Faissol Attux: 

AO MEU MARIDO, WILLIAN.
AOS MEUS PAIS, ALCENIR E
ARACI.

Agradecimentos

Agradeço,

a Deus, pela vida.

aos meus pais, Araci e Alcenir, por todo amor e apoio que sempre me deram.

ao meu marido, Willian, por todo amor e paciência. Obrigada pela ajuda, pelas sugestões e por ter sido meu maior motivador. Obrigada por estar sempre ao meu lado; você faz parte desta conquista.

ao meu irmão Danilo, que sempre me incentivou.

ao Prof. Akebo, pela orientação, confiança e apoio durante todos estes anos e pela oportunidade de iniciar uma carreira acadêmica.

ao Fabrício, por aceitar a co-orientação, por todas as discussões e sugestões sobre o trabalho.

aos professores da FEEC, IC, FEM e FEC pelos ótimos cursos oferecidos, que me serviram de motivação durante o doutorado.

aos membros da banca examinadora: Professor Ricardo Hiroshi Caldeira Takahashi, Professor Erlon Cristian Finardi, Professor Secundino Soares Filho e Professor Romis Ribeiro de Faisol Attux, por aceitarem o convite, pelos comentários, sugestões e contribuições.

aos amigos e colegas do Departamento de Telemática, pela ótima convivência, pelas discussões acadêmicas e conversas informais, que mantiveram nosso ambiente de trabalho sempre agradável.

à FEEC/UNICAMP, pela ótima estrutura que oferece aos estudantes e pesquisadores.

à CAPES, pelo apoio financeiro concedido durante todo o período de doutoramento.

à FAPESP, pelo apoio financeiro ao projeto regular, fundamental para a realização deste trabalho.

à todos que contribuíram para a realização deste trabalho.

Resumo

O Planejamento da Operação de Sistemas Hidrelétricos é um problema de otimização de grande porte, dinâmico, estocástico, interconectado e não-linear. Várias funções-objetivo podem ser utilizadas na representação dos diferentes aspectos do problema.

Neste trabalho foram propostas quatro abordagens para a resolução e estudo do problema. As propostas são baseadas em duas Metaheurísticas Evolutivas – Algoritmos Genéticos e Evolução Diferencial – e consideram o problema com as formulações Monobjetivo e Multiobjetivo. Os métodos trabalham simultaneamente com um conjunto de soluções, realizando exploração e exploração do espaço de busca.

Com foco principal na Otimização Multiobjetivo, o intuito é encontrar um conjunto de soluções, obtidas em uma única rodada do algoritmo, que possam agregar explicitamente os diferentes critérios do problema.

Os algoritmos propostos foram aplicados em vários testes com usinas pertencentes ao Sistema Hidrelétrico Brasileiro. Os resultados obtidos indicam que as abordagens propostas podem ser efetivamente aplicadas ao problema de Planejamento Hidrelétrico, fornecendo soluções alternativas e eficientes.

Este trabalho é uma contribuição tanto para o Problema de Planejamento Hidrelétrico, com a proposição de métodos de resolução que permitem a análise de vários aspectos do problema, quanto para a Computação Evolutiva, com a aplicação das técnicas em um problema importante e real.

Palavras-chave: Geração de Energia, Planejamento Hidrelétrico, Otimização Multiobjetivo, Algoritmos Evolutivos, Algoritmos Genéticos, Evolução Diferencial.

Abstract

The Operation Planning of Hydroelectric Systems is a large, dynamic, stochastic, interconnected and nonlinear optimization problem. Several objective functions can be used in the representation of different aspects of the problem.

In this work we proposed four approaches for the study and resolution of the problem. The proposals are based on two Evolutionary Metaheuristics – Genetic Algorithms and Differential Evolution – and consider the problem with single and multiobjective formulations. The methods work simultaneously with a set of solutions in order to perform exploration and exploitation of the search space.

With main focus on Multiobjective Optimization, the intent is to find a set of solutions, obtained in a single round of the algorithm, which can explicitly add the different criteria of the problem.

The proposed algorithms were applied to several tests with plants belonging to the Brazilian Hydropower System. The achieved results indicate that the proposed approaches can be effectively applied to the Hydropower Planning, providing efficient and alternative solutions.

This work is a contribution so much to the Problem of Hydropower Planning, with the proposition of resolution methods that allow the analysis of various aspects of the problem, as for the Evolutionary Computation, with the application of the techniques in a real and important problem.

Key-words: Power Generation, Hydroelectric Planning, Multiobjective Optimization, Evolutionary Algorithms, Genetic Algorithms, Differential Evolution.

Lista de Figuras

1.1	Matriz elétrica brasileira	6
1.2	Participação de renováveis na matriz elétrica	8
1.3	Exemplo de representação das vazões naturais e incrementais.	9
1.4	Vazões afluentes naturais mensais de Furnas, em m^3/s : últimos 25 anos.	10
1.5	Média de Longo Termo do histórico de vazões mensais, em m^3/s	10
1.6	Cronograma de decisão.	11
1.7	Esquema de uma usina hidrelétrica.	11
1.8	Abordagem em vigor	18
1.9	Representação da equação de balanceamento.	20
2.1	Mapeamento do espaço das soluções no espaço das funções-objetivo.	28
2.2	Conjunto das soluções Pareto-ótimas.	29
2.3	Dominância de Pareto no espaço objetivo.	30
2.4	Exemplo de Fronteiras global e local.	31
2.5	Processos de otimização e decisão: abordagem a priori.	32
2.6	Processos de otimização e decisão: abordagem interativa.	34
2.7	Processos de otimização e decisão: abordagem a posteriori.	35
3.1	Mutação, Cruzamento e Seleção da Evolução Diferencial.	42
4.1	Representação de um indivíduo da população.	54
4.2	Ordenação da população.	65
4.3	Cálculo da distância de aglomeração.	66
4.4	Esquema do processo seletivo para formação da população da geração $g + 1$: hidroNSGA e hidroNSDE.	67

5.1	Evolução do <i>fitness</i> do melhor indivíduo do hidroGA, em 10 rodadas de testes – Caso 1.	78
5.2	Evolução do <i>fitness</i> do melhor indivíduo do hidroDE, em 10 rodadas de testes – Caso 1.	78
5.3	Volumes dos Reservatórios, hidroGA – Caso 1.	79
5.4	Volumes dos Reservatórios, hidroDE – Caso 1.	79
5.5	Vazões de Furnas – Caso 1.	80
5.6	Vazões de Água Vermelha – Caso 1.	80
5.7	Geração Hidrelétrica mensal – Caso 1.	81
5.8	Volumes dos reservatórios, hidroGA – Caso 2.	83
5.9	Volumes dos reservatórios, hidroDE – Caso 2.	83
5.10	Geração Hidrelétrica mensal – Caso 2.	84
5.11	Volume útil (em %) e Vazão Turbinada (em m^3/s) de Furnas – Caso 1 e Caso 3.	85
5.12	Geração Hidrelétrica mensal – Caso 3.	86
5.13	Volumes dos Reservatórios – Caso 4.	89
5.14	Vazões de Ilha Solteira – Caso 4.	90
5.15	Geração Hidrelétrica – Caso 4.	90
5.16	Fronteiras não-dominadas, hidroNSGA, sem uniformização – Caso 5.	93
5.17	Fronteiras não-dominadas, hidroNSDE, sem uniformização – Caso 5.	93
5.18	Fronteiras não-dominadas, hidroNSGA, com uniformização – Caso 5.	94
5.19	Fronteiras não-dominadas, hidroNSDE, com uniformização – Caso 5.	94
5.20	Fronteiras não-dominadas, hidroNSGA – Caso 5.	94
5.21	Fronteiras não-dominadas, hidroNSDE – Caso 5.	95
5.22	Fronteiras não-dominadas, 10 rodadas, hidroNSGA – Caso 5.	96
5.23	Fronteiras não-dominadas, 10 rodadas, hidroNSDE – Caso 5.	96
5.24	Soluções não-dominadas, sem uniformização: reservatório de Furnas, hidroNSGA – Caso 5.	97
5.25	Soluções não-dominadas, sem uniformização: reservatório de Furnas, hidroNSDE – Caso 5.	97
5.26	Soluções não-dominadas, sem uniformização: reservatório de Água Vermelha, hidroNSGA – Caso 5.	97
5.27	Soluções não-dominadas, sem uniformização: reservatório de Água Vermelha, hidroNSDE – Caso 5.	97

5.28	Soluções não-dominadas, com uniformização: reservatório de Furnas, hidroNSGA	
	– Caso 5.	98
5.29	Soluções não-dominadas, com uniformização: reservatório de Furnas, hidroNSDE	
	– Caso 5.	98
5.30	Geração Hidrelétrica: soluções extremas, hidroNSGA – Caso 5.	98
5.31	Geração Hidrelétrica: soluções extremas, hidroNSDE – Caso 5.	99
5.32	Volume Útil (em [%]), hidroNSGA, com e sem uniformização – Caso 5.	100
5.33	Volume Útil (em [%]), hidroNSDE, com e sem uniformização – Caso 5.	100
5.34	Vazão Turbinada (em m^3/s), hidroNSGA, com e sem uniformização – Caso 5.	101
5.35	Vazão Turbinada (em m^3/s), hidroNSDE, com e sem uniformização – Caso 5.	101
5.36	Fronteiras não-dominadas, com alteração no volume inicial – Caso 5.	102
5.37	Soluções não-dominadas, com alteração no volume inicial: reservatório de Furnas, hidroNSGA – Caso 5.	103
5.38	Soluções não-dominadas, com alteração no volume inicial: reservatório de Furnas, hidroNSDE – Caso 5.	103
5.39	Geração Hidrelétrica, com alteração no volume inicial: soluções extremas, hidroNSGA – Caso 5.	103
5.40	Geração Hidrelétrica, com alteração no volume inicial: soluções extremas, hidroNSDE – Caso 5.	104
5.41	Fronteiras não-dominadas, com alteração na vazão natural afluyente – Caso 5.	104
5.42	Soluções não-dominadas, com alteração na vazão natural afluyente: reservatório de Furnas, hidroNSGA – Caso 5.	105
5.43	Soluções não-dominadas, com alteração na vazão natural afluyente: reservatório de Furnas, hidroNSDE – Caso 5.	105
5.44	Geração Hidrelétrica, com alteração na vazão natural afluyente: soluções extremas, hidroNSGA – Caso 5.	105
5.45	Geração Hidrelétrica, com alteração na vazão natural afluyente: soluções extremas, hidroNSDE – Caso 5.	106
5.46	Fronteiras não-dominadas, com e sem uniformização – Caso 6.	107
5.47	Soluções não-dominadas: reservatório de Furnas, hidroNSGA – Caso 6.	107
5.48	Soluções não-dominadas: reservatório de Furnas, hidroNSDE – Caso 6.	108
5.49	Volume Útil (em [%]) – Caso 6.	109
5.50	Vazão Turbinada (em m^3/s) – Caso 6.	109
5.51	Fronteiras não-dominadas – Caso 7.	110

5.52	Volumes dos Reservatórios, hidroNSGA – Caso 7.	111
5.53	Volumes dos Reservatórios, hidroNSDE – Caso 7.	112
5.54	Volumes dos Reservatórios – Caso 7.	114
5.55	Vazões de Ilha Solteira – Caso 7.	115
5.56	Fronteiras não-dominadas – Caso 8.	115
5.57	Geração Hidrelétrica: soluções extremas, hidroNSGA – Caso 8.	116
5.58	Geração Hidrelétrica: soluções extremas, hidroNSDE – Caso 8.	116
5.59	Fronteiras não-dominadas – Caso 9.	118
5.60	Geração Hidrelétrica: soluções extremas, hidroNSGA – Caso 9.	118
5.61	Volume útil [%]: soluções extremas, hidroNSGA – Caso 9.	118
5.62	Geração Hidrelétrica: soluções extremas, hidroNSDE – Caso 9.	119
5.63	Volume útil [%]: soluções extremas, hidroNSDE – Caso 9.	119
5.64	Vazão Natural Afluente de Nova Ponte – Caso 9.	119
A.1	Vazões de Furnas, HydroMax – Caso 1.	137
A.2	Vazões de Água Vermelha, HydroMax – Caso 1.	137
A.3	Volumes dos Reservatórios, HydroMax – Caso 1.	137
A.4	Volumes dos Reservatórios, HydroMax – Caso 2.	138
A.5	Volumes dos Reservatórios, HydroMax – Caso 3.	138
A.6	Volumes dos Reservatórios, HydroMax – Caso 4.	139
A.7	Geração Hidrelétrica, HydroMax – Caso 9.	140
A.8	Volume útil [%], HydroMax – Caso 9.	140
B.1	35 usinas hidrelétricas da região Sudeste - Brasil.	141

Lista de Tabelas

1.1	Capacidade instalada de geração de energia, em MW	6
1.2	Capacidade instalada de geração de energia, por região, em %	7
1.3	Potencial Hidráulico por região, em %	7
5.1	Geração Hidrelétrica ($\overline{MW}$), $G = 50$ gerações, Média, Desvio e Total – Caso 1. .	76
5.2	Geração Hidrelétrica ($\overline{MW}$), $G = 100$ gerações, Média, Desvio e Total – Caso 1.	76
5.3	Geração Hidrelétrica ($\overline{MW}$), $G = 150$ gerações, Média, Desvio e Total – Caso 1.	77
5.4	Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 50$, $G = 100$ e $G = 150$ – Caso 1.	78
5.5	Geração Hidrelétrica ($\overline{MW}$), $G = 600$ gerações, Média, Desvio e Total – Caso 2.	82
5.6	Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 600$ – Caso 2.	82
5.7	Geração Hidrelétrica ($\overline{MW}$), $G = 100$ gerações, Média, Desvio e Total – Caso 3.	84
5.8	Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 100$ – Caso 3.	85
5.9	Geração Hidrelétrica ($\overline{MW}$), $G = 1000$ gerações, Média, Desvio e Total – Caso 4.	87
5.10	Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 1000$ – Caso 4.	88
5.11	Número de soluções não-dominadas e tempo de execução (em segundos) – Caso 5.	92
5.12	Dispersão, número de soluções não-dominadas e tempo de execução (em segun- dos) – Caso 5.	96
5.13	Geração Hidrelétrica ($\overline{MW}$) – Caso 5.	99
5.14	Médias dos Volumes Finais dos Reservatórios (em [%] do volume útil) – Caso 5.	99
5.15	Dispersão, número de soluções não-dominadas e tempo de execução (em segun- dos), com alteração no volume inicial – Caso 5.	102

5.16	Dispersão, número de soluções não-dominadas e tempo de execução (em segundos), com alteração na vazão natural afluyente – Caso 5.	104
5.17	Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 6.	107
5.18	Geração Hidrelétrica ($\overline{MW}$) – Caso 6.	108
5.19	Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 7.	110
5.20	Geração Hidrelétrica ($\overline{MW}$) – Caso 7.	113
5.21	Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 8.	115
5.22	Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 9.	118
A.1	Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 1.	138
A.2	Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 2.	138
A.3	Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 3.	139
A.4	Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 4.	139
A.5	Energia total (MWh) e Mínima potência ($\overline{MW}$), referentes à geração hidrelétrica $H(t)$ maximizada, HydroMax – Caso 9.	140

Lista de Acrônimos e Notação

T : número de intervalos de tempo

N : número de usinas hidrelétricas

Δt : tamanho de cada intervalo de tempo $[s]$

Ω_i : conjunto das usinas imediatamente a montante da usina i

$k(i)$: produtividade específica da usina i

$\mathcal{C}(\cdot)$: função de custo da geração termelétrica $[\$]$

$\tau(t)$: coeficiente de valor presente para o intervalo t

$D(t)$: demanda a ser atendida no intervalo t $[\overline{MW}]$

$H(t)$: geração hidrelétrica total no intervalo t $[\overline{MW}]$

$G(t)$: geração termelétrica total no intervalo t $[\overline{MW}]$

$q(i, t)$: vazão turbinada pela usina i no intervalo t $[m^3/s]$

$z(i, t)$: vazão vertida pela usina i no intervalo t $[m^3/s]$

$u(i, t)$: vazão defluente da usina i no intervalo t $[m^3/s]$

$y(i, t)$: vazão incremental afluyente à usina i no intervalo t $[m^3/s]$

$x(i, t)$: volume do reservatório da usina i no início do intervalo t $[hm^3]$

$p(i, t)$: geração da usina hidrelétrica i no intervalo t $[\overline{MW}]$

$h(i, t)$: altura da queda bruta da usina i no intervalo t $[m]$

$x_{med}(i, t)$: volume médio do reservatório da usina i no intervalo t $[hm^3]$

$\phi(i, x(i, t))$: polinômio da cota de montante do reservatório da usina i

$\theta(i, u(i, t))$: polinômio da cota de jusante do canal de fuga da usina i

$x_{min}(i)$: volume mínimo do reservatório da usina i [hm^3]
 $x_{max}(i)$: volume máximo do reservatório da usina i [hm^3]
 $q_{max}(i)$: máxima vazão turbinada pela usina i [m^3/s]
 $u_{min}(i)$: mínima vazão defluente da usina i [m^3/s]
 δ_c : fator de conversão de unidades, de $[\overline{MW}]$ para $[MWh]$

TP : tamanho da população

G : número de gerações

PM : probabilidade de mutação do Algoritmo Genético

PC : probabilidade de cruzamento do Algoritmo Genético

F : constante de mutação da Evolução Diferencial

CR : probabilidade de cruzamento da Evolução Diferencial

P_g : população da g -ésima geração

Q_g : população de filhos da g -ésima geração

R_g : população auxiliar da g -ésima geração

$rank_k$: classificação não-dominada da k -ésima solução da população

$crowd_k$: distância de aglomeraçãoda k -ésima solução da população

f_j : j -ésima função objetivo

F_l : l -ésima fronteira não-dominada

S_p : conjunto de soluções que a solução p domina

n_p : número de soluções que dominam a solução p .

$p \preceq^* q$: nova ordem parcial: a solução representada pelo indivíduo p é melhor que a solução representada pelo indivíduo q . Leva em consideração os valores de $rank$ e $crowd$

nd : número de soluções não-dominadas

D_S : variância da distância de cada membro da fronteira em relação ao seu vizinho mais próximo

Sumário

Introdução	1
1 Planejamento da Operação de Sistemas Hidrelétricos	5
1.1 Geração de Energia Elétrica no Brasil	5
1.2 Apresentação do Problema e Formulação Matemática	8
1.3 Múltiplos Objetivos	14
1.4 Diferentes Horizontes de Planejamento e Intervalos de Discretização	15
1.5 Revisão Bibliográfica	17
2 Otimização Multiobjetivo	27
2.1 Definições	28
2.2 Métodos de Resolução	32
2.2.1 Métodos a Priori	32
2.2.2 Métodos Iterativos	34
2.2.3 Métodos a Posteriori	35
3 Algoritmos Evolutivos	39
3.1 Algoritmos Genéticos	40
3.2 Evolução Diferencial	42
3.3 Algoritmos Evolutivos e Otimização Multiobjetivo	43
4 Métodos de Resolução Propostos	53
4.1 Formulação Monobjetivo: hidroGA e hidroDE	53
4.1.1 Formulação Monobjetivo e Algoritmo Genético: hidroGA	61
4.1.2 Formulação Monobjetivo e Evolução Diferencial: hidroDE	63
4.2 Formulação Multiobjetivo: hidroNSGA e hidroNSDE	64

4.2.1	Formulação Multiobjetivo e Algoritmo Genético: hidroNSGA	70
4.2.2	Formulação Multiobjetivo e Evolução Diferencial: hidroNSDE	71
5	Estudos de Caso	73
5.1	Formulação Monobjetivo: hidroGA e hidroDE	74
5.1.1	Caso 1: Operação em Cascata: Furnas e Água Vermelha	75
5.1.2	Caso 2: Horizonte de Planejamento de 48 meses	81
5.1.3	Caso 3: Usina a Fio d'água	83
5.1.4	Caso 4: 14 usinas	86
5.2	Formulação Multiobjetivo: hidroNSGA e hidroNSDE	88
5.2.1	Caso 5: Custo da Complementação Térmica e Volume Final: 2 usinas . .	91
5.2.2	Caso 6: Custo da Complementação Térmica e Volume Final: 2 usinas, 48 meses	106
5.2.3	Caso 7: Custo da Complementação Térmica e Volume Final: 14 usinas .	109
5.2.4	Caso 8: Custo da Complementação Térmica e Volume Final: 35 usinas .	113
5.2.5	Caso 9: Energia Total e Mínima Potência: Nova Ponte	117
6	Conclusões e Perspectivas	121
	Bibliografia	125
A	Resultados do Modelo HydroMax	137
B	Usinas Hidrelétricas dos Estudos de Caso	141

Introdução

Um Sistema Elétrico é dividido em três partes: geração, transmissão e distribuição. A geração pode ser obtida de forma hidrelétrica, térmica, alternativa (eólica, solar, biomassa) e, eventualmente, por importação de sistemas vizinhos. Toda a energia elétrica disponível é enviada através das linhas de transmissão e distribuição que conduzem a energia das fontes geradoras até os mercados consumidores para o atendimento da demanda (Cicogna & Soares 2005, Leite et al. 2006).

O processo de geração de energia hidrelétrica baseia-se na transformação de energia potencial hidráulica, resultante do aproveitamento de quedas d'água, em energia elétrica. Em sistemas com grande participação de geração hidrelétrica, como no caso do Brasil, pode-se gerenciar a energia potencial da água armazenada nos reservatórios para atender à demanda e substituir de forma racional a geração dispendiosa das unidades térmicas. O planejamento deve estabelecer um compromisso entre a geração hidrelétrica no momento da decisão e a disponibilidade de água nos intervalos de tempo seguintes, respeitando as restrições do problema.

As características dos sistemas hidrelétricos afetam os dois principais objetivos da operação: economia e confiabilidade. A política econômica seria optar, a cada etapa, pela máxima utilização das usinas hidrelétricas na geração de energia, através do deplecionamento dos reservatórios. Isto minimizaria o custo de operação do sistema, porém, aumentaria o risco de déficit, tornando-o pouco confiável. Por sua vez, a máxima confiabilidade de fornecimento é obtida conservando o nível dos reservatórios o mais elevado possível. Entretanto, isto significa uma maior utilização de geração térmica complementar e conseqüentemente um aumento dos custos operacionais.

Inicialmente restritos a problemas que envolviam um único objetivo, os modelos de otimização e as técnicas associadas evoluíram com o intuito de contemplarem a situação mais realista em que vários objetivos, em geral conflitantes, concorrem para a solução de um determinado problema (Ferreira 1999). Um problema de Otimização Multiobjetivo pode ser definido como a

otimização de uma função vetorial, cujos elementos representam cada uma das funções-objetivo (Osyczka 1985). A solução esperada é composta por um conjunto parcialmente ordenado de pontos de equilíbrio, ou seja, uma família de soluções consideradas iguais entre si e superiores em relação ao restante das soluções. Desta forma, existem alternativas factíveis que não satisfazem nenhuma relação de ordem, do tipo “menor ou igual”, inviabilizando a utilização do conceito usual de solução ótima adotado em problemas monobjetivos.

Na área de Pesquisa Operacional, existem várias técnicas de Programação Matemática que foram propostas para a resolução dos problemas de Otimização Multiobjetivo. Porém, muitas dessas técnicas têm alta complexidade e apresentam dificuldades no tratamento de certos tipos de problemas, pois são fundamentadas em informações que restringem ou dificultam uma aplicação geral. Além disso, estas técnicas tendem a gerar somente uma solução a cada execução do algoritmo (Coello 2002).

Dentre os Métodos Metaheurísticos, estão os Algoritmos Evolutivos. Inspirados em mecanismos da evolução biológica, estes algoritmos vêm sendo amplamente utilizados em diversas aplicações, principalmente na área de otimização. Considerando que a solução de um problema de Otimização Multiobjetivo é constituída por um conjunto de pontos, a utilização de Algoritmos Evolutivos parece imediata, pois consideram simultaneamente um conjunto de soluções (paralelismo). Com a integração da ampla exploração do espaço de busca com um processo de busca mais localizada (explotação), estes métodos possuem alto grau de robustez, o que permite que sejam aplicados em vários problemas práticos, junto aos quais outras estratégias de solução se mostram ineficientes (Bäck et al. 2000a, Bäck et al. 2000b).

Alguns pesquisadores têm sugerido que a Otimização Multiobjetivo deve ser uma área em que os Algoritmos Evolutivos apresentariam desempenho melhor do que outras estratégias de busca (Toro et al. 2006). Algumas características destes métodos merecem ser destacadas: flexibilidade, generalidade, capacidade de escapar de ótimos locais, capacidade de lidar com problemas complexos para os quais não é possível, ou é difícil, obter uma descrição detalhada, além de serem menos susceptíveis à forma ou continuidade das funções (Bäck et al. 2000a, Bäck et al. 2000b, Coello 2002, Coello & Cortés 2005a). Além disso, os problemas reais têm se tornado cada vez mais complexos, sem funções definidas ou bem comportadas e muitas vezes descontínuas e com domínios não-convexos, dificultando a utilização de métodos exatos na resolução.

As técnicas tradicionais exigem o conhecimento prévio do problema, uma especificação detalhada com indicação de ponderações, metas ou preferências, o que quase sempre não é possível, além de ser uma forma reduitiva e não natural de abordar um problema de tomada de decisão (Filgueira et al. 2005). Já os Algoritmos Bio-inspirados requerem apenas uma descrição aproxi-

mada das características que representem o comportamento global, como uma função ou medida de afinidade, adaptabilidade ou desempenho.

Motivação

Está definido no Manual do Programa de Pesquisa e Desenvolvimento Tecnológico do Setor de Energia Elétrica¹ que são de interesse da Agência Nacional de Energia Elétrica (ANEEL) projetos destinados ao desenvolvimento de metodologias, técnicas e ferramentas de auxílio que integrem modelos matemáticos, técnicas de programação matemática e de inteligência artificial, visando o planejamento e a melhor aplicação dos recursos que necessitam de suporte à tomada de decisões.

O Planejamento da Operação de Sistemas Hidrelétricos é um problema de otimização de grande porte, dinâmico, estocástico, interconectado e não-linear. Muitos trabalhos apresentados na literatura são modelos computacionais que consideram como função-objetivo apenas o custo total de operação. Por outro lado, existem várias funções-objetivo para a representação dos diferentes aspectos do problema; por exemplo, que consideram a segurança energética (através da minimização de um custo associado ao déficit ou minimização do risco de não atendimento da demanda) e critérios operacionais (metas para os volumes dos reservatórios ou geração hidrelétrica total). Além disso, o setor elétrico praticou, por diversas vezes, decisões diferentes das fornecidas pelos modelos computacionais oficialmente adotados (Kligerman 2009), o que motiva o estudo de abordagens capazes de apresentar um conjunto de soluções, distintas e de boa qualidade.

Em relação aos problemas de otimização, muitos pesquisadores (Knowles et al. 2008) têm incentivado questões do tipo: e se minha função for uma representação imprecisa da verdadeira função-objetivo? O que aconteceria se retirássemos uma restrição e a tratássemos como mais um objetivo do problema? O que aconteceria se tivéssemos um problema com um único objetivo, mas que fosse possível decompô-lo em múltiplos objetivos?

A partir destas considerações, e conhecendo a importância e a relevância do problema, surgiu o interesse em estudar a aplicação de Metaheurísticas para o Planejamento Hidrelétrico, mais especificamente, dois Algoritmos Evolutivos: Algoritmos Genéticos e Evolução Diferencial. Com foco na Otimização Multiobjetivo, o objetivo é encontrar um conjunto de soluções, obtidas em uma única execução do algoritmo, que possam agregar explicitamente diferentes critérios do problema.

¹http://www.aneel.gov.br/visualizar_texto.cfm?idtxt=1615

Na primeira parte da tese, foram propostos dois algoritmos para resolução do Problema de Planejamento Hidrelétrico com um único objetivo: hidroGA e hidroDE. Existem vários métodos exatos e eficientes para a resolução do problema com esta formulação², o que faz com que a utilização de metaheurísticas não seja uma necessidade para este tipo de problema. O intuito da proposição desses métodos com a formulação monobjetivo é a validação das metaheurísticas na resolução do problema em sua forma simples. Após a validação dos resultados obtidos pelo hidroGA e pelo hidroDE, na segunda parte da tese, outros dois algoritmos foram propostos: hidroNSGA e hidroNSDE. Estes algoritmos abordam o problema com múltiplos objetivos. E a Otimização Multiobjetivo, como será discutido nas próximas seções, é uma área onde a aplicação de Metaheurísticas se faz necessária para a resolução do problema de forma eficiente.

Organização da Tese

Este trabalho foi organizado da seguinte maneira:

- O Capítulo 1 apresenta o Problema de Planejamento Hidrelétrico, sua formulação matemática e a revisão bibliográfica dos trabalhos propostos na literatura sobre o tema.
- No Capítulo 2 são apresentados os conceitos de Otimização Multiobjetivo utilizados ao longo do estudo e a revisão bibliográfica das técnicas de resolução.
- O Capítulo 3 apresenta conceitos dos Algoritmos Evolutivos abordados no estudo: Algoritmo Genético e Evolução Diferencial, justificando a escolha destes métodos para a resolução do problema. Discute-se também a aplicação dos Algoritmos Evolutivos na resolução de Problemas de Otimização Multiobjetivo.
- No Capítulo 4 são apresentadas e discutidas as funcionalidades e características dos quatro algoritmos implementados para o estudo do problema: hidroGA, hidroDE, hidroNSGA e hidroNSDE.
- O Capítulo 5 apresenta alguns estudos de caso, juntamente com as comparações e discussões dos resultados.
- Finalmente, as conclusões do trabalho e as perspectivas de estudos complementares são apresentadas no Capítulo 6.

²(Soares & Carneiro 1991, Oliveira & Soares 1995, Cicogna 1999) dentre outros, com mais detalhes na Revisão Bibliográfica, Seção 1.5.

Planejamento da Operação de Sistemas Hidrelétricos

Este capítulo apresenta o problema que é tema deste trabalho – Planejamento da Operação de Sistemas Hidrelétricos, com ênfase no sistema brasileiro de geração de energia elétrica e suas principais características. A Seção 1.1 apresenta os dados de capacidade instalada e potencial energético, para as diferentes fontes de geração e regiões brasileiras. A Seção 1.2 apresenta os principais componentes de uma usina hidrelétrica, a formulação matemática do modelo a usinas individualizadas e suas variáveis. Diferentes objetivos para a formulação do problema são descritos na Seção 1.3. A Seção 1.4 faz considerações sobre os diferentes horizontes de planejamento e intervalos de discretização que podem ser abordados no problema. A Seção 1.5 faz uma revisão bibliográfica das metodologias em vigor no setor elétrico e outras abordagens propostas na literatura.

1.1 Geração de Energia Elétrica no Brasil

O crescimento econômico e tecnológico de um país depende de sua capacidade de geração de energia. A geração de energia elétrica no Brasil atingiu 568,8 TWh em 2011. A principal fonte é a energia hidráulica com 81,7% da geração total (Figura 1.1), com crescimento de 6,33% em relação a 2010 (EPE 2012).

No parque gerador brasileiro, outras fontes estão sendo incorporadas, como revela o aproveitamento de potenciais eólicos e de energia solar. Porém, são fontes que ainda representam valores inexpressivos frente ao montante de energia elétrica necessário ao atendimento da demanda atual (Toscano 2009). A capacidade instalada de geração, em MW , de cada fonte de energia, está apresentada na Tabela 1.1.




Figura 1.1: Matriz elétrica brasileira (EPE 2012).

Hidráulica	Térmica	Eólica	Nuclear	Total
80.703	29.689	928	2.007	113.327

Tabela 1.1: Capacidade instalada de geração de energia, em *MW* (EPE 2011).

Tudo indica que a energia hidráulica continuará sendo, por muitos anos, a principal fonte geradora de energia elétrica do Brasil. A continuação dos investimentos em diferentes fontes de energia elétrica é importante para a diversificação na matriz energética brasileira. O planejamento da geração com os recursos já existentes é de suma importância para eficiência e segurança energética.

A maior parte da capacidade instalada é composta por usinas hidrelétricas, que se distribuem em oito grandes bacias hidrográficas: rio Amazonas, rios Tocantins e Araguaia, Atlântico Norte/Nordeste, rio São Francisco, Atlântico Leste, rios Paraná e Paraguai, rio Uruguai e Atlântico Sul/Sudeste (ANEEL 2005). O Sistema Interligado Nacional (SIN) permite intercâmbios de energia entre as diferentes regiões do País, quando uma delas apresenta queda no nível dos reservatórios. Como o regime de chuvas é diferente nas regiões Sul, Sudeste, Norte e Nordeste, os grandes troncos (linhas de transmissão de alta tensão) possibilitam que os pontos com produção insuficiente de energia sejam abastecidos por centros de geração em situação favorável (ANEEL 2012). A Tabela 1.2 apresenta a capacidade instalada de cada fonte de energia em cada região brasileira.

O potencial hidrelétrico brasileiro é estimado em 243.362 *GW*. Destes, 33,2% estão em operação e 2,3% em construção (EPE 2011). Entende-se por potencial hidrelétrico o potencial

Região	Hidráulica	Térmica	Eólica	Nuclear	Total
Norte	13,5	11,4	0	0	12,6
Nordeste	13,6	19,9	78,0	0	15,5
Sudeste	30,4	46,1	3,1	100	35,5
Sul	28,7	14,1	18,8	0	24,3
Centro-Oeste	13,8	8,4	0	0	12,0

Tabela 1.2: Capacidade instalada de geração de energia, por região, em % (EPE 2011).

possível de ser tecnicamente e economicamente aproveitado nas condições atuais de tecnologia. Embora os maiores potenciais remanescentes estejam localizados em regiões com fortes restrições ambientais e distantes dos principais centros consumidores, estima-se que, nos próximos anos, pelo menos 50% da necessidade de expansão da capacidade de geração seja de origem hídrica (ANEEL 2002). A Tabela 1.3 apresenta o potencial hidráulico de cada região brasileira.

Norte	Nordeste	Sudeste	Sul	Centro-Oeste
40,0	10,3	18,1	17,2	14,5

Tabela 1.3: Potencial Hidráulico por região, em % (EPE 2011).

No entanto, é necessário precaução quando se trata dos números apresentados para este potencial, uma vez que eles não consideram o efeito da legislação ambiental sobre os projetos potenciais (dos Reis 2011).

No cenário mundial¹ (Figura 1.2), o Brasil tem grande destaque em relação à participação de energias renováveis em sua matriz elétrica. Em 2011, esta participação ampliou-se para 88,8% devido às condições hidrológicas favoráveis e ao aumento da geração eólica (EPE 2012).

Fontes renováveis são aquelas cuja reposição pela natureza é bem mais rápida do que sua utilização energética (como as águas dos rios, marés, sol, ventos) ou cujo manejo pelo homem pode ser efetuado de forma compatível com as necessidades de sua utilização energética (como a biomassa). A maioria dessas fontes apresenta características estocásticas, de certa forma cíclicas, em períodos de tempo compatíveis com a operação das usinas elétricas e inferiores à vida útil das mesmas. Tais fontes podem ser usadas para produzir eletricidade através de usinas hidrelétricas, eólicas ou solar-fotovoltaicas (dos Reis 2011).

São consideradas fontes não-renováveis aquelas passíveis de se esgotarem por serem utilizadas com velocidade bem maior que os milhares de anos necessários para sua formação. Nesta categoria estão os derivados do petróleo, os combustíveis radioativos, a energia geotérmica e o gás natural. Atualmente, a utilização de tais fontes para produzir eletricidade se dá principalmente

¹Países membros da OECD: <http://www.oecd.org>




Figura 1.2: Participação de renováveis na matriz elétrica (EPE 2012).

através de uma primeira transformação da fonte primária em energia térmica, por exemplo, por meio de combustão, fissão ou processos geotérmicos (dos Reis 2011).

1.2 Apresentação do Problema e Formulação Matemática

Desde meados da década de 70, o sistema elétrico brasileiro é operado de forma coordenada, visando minimizar os custos de produção de energia elétrica e aumentando a confiabilidade do atendimento. A dependência operativa é causada pelo aproveitamento conjunto dos recursos hidrelétricos, através da construção e da operação de usinas e reservatórios localizados em sequência em várias bacias hidrográficas. Desta forma, a operação de uma determinada usina depende das vazões liberadas a montante por outras usinas, ao mesmo tempo em que sua operação afeta as usinas a jusante (Zancheta 2005).

A vazão que chega ao reservatório de cada usina é chamada de vazão afluyente. A vazão afluyente regularizada é a vazão controlável que passa por uma seção transversal do manancial, considerando todas as descargas hidráulicas a montante da seção. A vazão afluyente incremental que passa por uma seção transversal corresponde à vazão lateral gerada pela área de drenagem a montante da usina; esta vazão não pode ser alterada pela operação dos reservatórios a montante e por isso é chamada de vazão não-controlável. As vazões defluentes das usinas imediatamente a montante correspondem à vazão controlável.

Considerando as quatro usinas com reservatório mostradas na Figura 1.3, as vazões incrementais às usinas 1 e 3, são iguais às vazões afluentes naturais, respectivamente y_1 e y_3 . A

vazão afluyente à usina 2 será igual à sua vazão afluyente natural, y_2 , somente se a usina 1 for operada a fio d'água, ou seja, se o volume de água armazenado no reservatório da usina 1 for mantido constante. Geralmente, esta operação não é verificada; logo a vazão afluyente à usina 2 pode ser determinada como a soma da vazão defluente da usina 1 e da vazão incremental (y_2^{inc}) da usina 2. A usina 4 recebe as vazões controláveis provenientes das usinas 2 e 3 mais a vazão incremental (y_4^{inc}) da área de drenagem da seção 4.




Figura 1.3: Exemplo de representação das vazões naturais e incrementais.

Seja y_i a vazão natural da usina i , em m^3/s ; y_i^{inc} a vazão incremental da usina i , em m^3/s ; e Ω_i o conjunto das usinas imediatamente a montante da usina i . Pode-se calcular, genericamente:

$$y_i^{inc} = y_i - \sum_{k \in \Omega_i} y_k \quad (1.1)$$

As usinas brasileiras possuem um histórico² de vazões afluentes naturais, diárias e mensais, desde 1931. A Figura 1.4 apresenta as vazões afluentes naturais mensais da usina de Furnas nos últimos 25 anos. A Figura 1.5 apresenta Média de Longo Termo (MLT) de Furnas. A MLT representa a média aritmética das vazões naturais afluentes, sendo considerado no exemplo, o histórico mensal de vazões.

Percebe-se um comportamento cíclico anual. No caso de Furnas, o período seco acontece entre os meses de maio e novembro (quando a MLT está abaixo da média anual) e o período úmido se inicia em dezembro e vai até abril. Estes períodos dependem da bacia e da localização geográfica da usina.

²http://www.ons.org.br/operacao/vazoes_naturais.aspx




Figura 1.4: Vazões afluentes naturais mensais de Furnas, em m^3/s : últimos 25 anos.




Figura 1.5: Média de Longo Termo do histórico de vazões mensais, em m^3/s .

O volume de água armazenado nos reservatórios é incerto, pois depende das afluências que irão ocorrer no futuro (Figura 1.6). Isso introduz uma relação entre a decisão de operação no presente e suas consequências futuras (Leite et al. 2006). Se a decisão for utilizar energia hidrelétrica para atender o mercado, deplecionando os reservatórios, e no futuro ocorrer uma seca, pode haver a necessidade de utilizar a geração térmica ou interromper o fornecimento de energia. Se a opção for conservar os reservatórios cheios e utilizar a geração térmica, na ocorrência de grandes vazões afluentes, pode haver vertimento no sistema, ou seja, desperdício de energia e, em consequência, um aumento desnecessário do custo de operação.

A Figura 1.7 apresenta um esquema de uma usina hidrelétrica e as principais variáveis que compõem o modelo.

Uma barragem represa a água para a formação do reservatório e aumenta a altura de queda d'água h . Dependendo da capacidade de regularização, um reservatório é classificado como:




Figura 1.6: Cronograma de decisão.




Figura 1.7: Esquema de uma usina hidrelétrica.

de acumulação, quando tem capacidade para regularizar as vazões de um mês, de um ano ou até de vários anos; ou de compensação, se o volume é suficiente somente para a regularização das vazões semanais ou diárias. São utilizadas as seguintes nomenclaturas: usinas a fio d'água, se possuem reservatórios de compensação; e usinas com reservatório, se possuem reservatórios de acumulação. Os reservatórios de acumulação atenuam bastante o efeito da variação das afluências naturais, devido ao armazenamento em períodos de cheia e ao deplecionamento em períodos de seca.

O canal de adução conduz sob pressão a água armazenada no reservatório para o conjunto de turbinas (casa de máquinas). Na casa de máquinas, a água é utilizada para girar as pás das

turbinas. As turbinas são conectadas a geradores que convertem energia cinética em energia elétrica. Depois disso, a água retorna à bacia através do canal de fuga da usina.

No vertedouro, a água em excesso é liberada, sem que se gere energia. Isto acontece em situações em que a geração de energia não é suficiente para a quantidade de vazão afluente ao reservatório. O vertedouro é projetado a partir de estudos estatísticos baseados no histórico de vazões, de forma a prever uma possível grande cheia; para isto, calcula-se a chamada cheia decamilenar, isto é, a maior cheia em 10.000 anos. O vertimento é um desperdício de energia e deve ser evitado sempre que possível. O ideal é utilizá-lo apenas como operação de segurança: a água que não pode ser utilizada na geração de energia por restrições operativas e que não pode ser armazenada no reservatório deve ser vertida para não comprometer a estrutura física da barragem.

As variáveis e os parâmetros envolvidos no modelo de múltiplas usinas hidrelétricas individualizadas para Sistemas Hidrelétricos de geração são:

T : número de intervalos de tempo.

N : número de usinas hidrelétricas.

Δt : tamanho de cada intervalo de tempo [s].

Ω_i : conjunto das usinas imediatamente a montante da usina i .

$k(i)$: produtividade específica³ da usina i [$\frac{MW}{(m^3/s).m}$].

$\mathcal{C}(\cdot)$: função de custo da geração termelétrica [\$].

$\tau(t)$: coeficiente de valor presente para o intervalo t .

$D(t)$: demanda a ser atendida no intervalo t [MW].

$H(t)$: geração hidrelétrica total no intervalo t [MW].

$G(t)$: geração termelétrica total no intervalo t [MW].

$q(i, t)$: vazão turbinada pela usina i no intervalo t [m^3/s].

$z(i, t)$: vazão vertida pela usina i no intervalo t [m^3/s].

$u(i, t)$: vazão defluente da usina i no intervalo t [m^3/s].

$y(i, t)$: vazão incremental afluente à usina i no intervalo t [m^3/s].

$x(i, t)$: volume do reservatório da usina i no início do intervalo t [hm^3].

³Constante que engloba aceleração da gravidade, densidade da água, rendimento turbina-gerador e fatores de conversão.

$p(i, t)$: geração da usina hidrelétrica i no intervalo t $[\overline{MW}]$.

$h(i, t)$: altura da queda bruta da usina i no intervalo t $[m]$.

$x_{med}(i, t)$: volume médio do reservatório da usina i no intervalo t $[hm^3]$.

$\phi(i, x(i, t))$: cota de montante do reservatório da usina i .

$\theta(i, u(i, t))$: cota de jusante do canal de fuga da usina i .

$x_{min}(i)$: volume mínimo do reservatório da usina i $[hm^3]$.

$x_{max}(i)$: volume máximo do reservatório da usina i $[hm^3]$.

$q_{max}(i)$: máxima vazão turbinada pela usina i $[m^3/s]$.

$u_{min}(i)$: mínima vazão defluente da usina i $[m^3/s]$.

O setor elétrico, atualmente, utiliza a modelagem formalmente desenvolvida como monobjetivo para a minimização do custo, com a segurança energética tratada externamente como restrição operativa (Kligerman 2009). A seguir a formulação matemática do modelo (Cicogna & Soares 2005):

$$\text{Minimizar} \quad \sum_{t=1}^T \left[\tau(t) \mathcal{C}(G(t)) \right] \quad (1.2)$$

$$\text{Sujeito a} \quad G(t) = D(t) - H(t) \quad (1.3)$$

$$H(t) \leq D(t) \quad (1.4)$$

$$H(t) = \sum_{i=1}^N p(i, t) \quad (1.5)$$

$$p(i, t) = k(i) h(i, t) q(i, t) \quad (1.6)$$

$$h(i, t) = \phi(i, x_{med}(i, t)) - \theta(i, u(i, t)) \quad (1.7)$$

$$x_{med}(i, t) = \frac{x(i, t) + x(i, t+1)}{2} \quad (1.8)$$

$$x(i, t+1) = x(i, t) + \left\{ y(i, t) - q(i, t) - z(i, t) + \sum_{k \in \Omega_i} \left[q(k, t) + z(k, t) \right] \right\} \frac{\Delta t}{10^6} \quad (1.9)$$

$$u(i, t) = q(i, t) + z(i, t) \quad (1.10)$$

$$x_{min}(i) \leq x(i, t) \leq x_{max}(i) \quad (1.11)$$

$$q(i, t) \leq q_{max}(i) \quad (1.12)$$

$$u(i, t) \geq u_{min}(i) \quad (1.13)$$

$$\forall i = 1, \dots, N, \quad \forall t = 1, \dots, T$$

O sistema termelétrico é representado por uma única usina térmica com capacidade de geração ilimitada e função de custo convexa crescente, próxima de um polinômio de segundo grau (El-Hawary & Christensen 1979). Por simplificação:

$$\mathcal{C}(G(t)) = (G(t))^2 \quad (1.14)$$

Deve-se considerar uma taxa de juros na manipulação deste custo. O principal objetivo é poder trazer para o início do horizonte (valor presente dos custos) o custo total resultante do planejamento energético (Cicogna 1999). O coeficiente de valor presente para o intervalo t é então definido como:

$$\tau(t) = \frac{1}{(1+r)^t} \quad (1.15)$$

onde r é a taxa de juros efetiva para cada intervalo do horizonte de planejamento. Esta taxa afeta a operação diminuindo mais rapidamente os níveis dos reservatórios no início do horizonte e adiando a geração térmica para o final do período de planejamento.

A função de geração hidrelétrica (Equação 1.6) é não-linear. A queda líquida $h(i, t)$ é função da cota de montante $\phi(i, x(i, t))$ e da cota de jusante $\theta(i, u(i, t))$, que são respectivamente, funções aproximadas por polinômios de quarto grau.

1.3 Múltiplos Objetivos

Dentre os possíveis objetivos (Barros et al. 2005, Cicogna & Soares 2005, Scola et al. 2011b) a serem tratados estão:

Minimizar o Custo da Complementação Térmica

Em uma usina termelétrica, o custo é fortemente dependente da geração, uma vez que o consumo de combustível é proporcional ao nível de geração da usina.

$$\text{Minimizar} \quad \sum_{t=1}^T \left[\tau(t) \left(D(t) - H(t) \right)^2 \right] \quad (1.16)$$

Maximizar a Geração de Energia

A geração de energia depende da altura de queda bruta $h(i, t)$, que é função do volume armazenado. Se considerarmos somente a geração hidrelétrica, sem restrição de volume final, os

reservatórios serão deplecionados, em busca da máxima vazão turbinada.

$$\text{Maximizar} \quad \sum_{t=1}^T H(t) \quad (1.17)$$

Maximizar a mínima potência gerada mensalmente

Importante quando o regime pluviométrico está sujeito a grandes variações que, na ausência de um grande reservatório, produziriam variações correspondentes na geração hidrelétrica.

$$\text{Maximizar} \quad \min_t \left[H(t) \right] \quad \forall t \in \{1, 2, \dots, T\} \quad (1.18)$$

Maximizar o volume final dos reservatórios

A maximização do volume final dos reservatórios é conflitante com os objetivos de minimização do custo da complementação térmica e de maximização da geração de energia.

$$\text{Maximizar} \quad \sum_{i=1}^N x(i, T) \quad (1.19)$$

Minimizar o desvio do volume armazenado

Seja $s(i, t)$ a meta para o volume do reservatório da usina i no período t .

$$\text{Minimizar} \quad \sum_{i=1}^N \sum_{t=1}^T \left(s(i, t) - x(i, t) \right)^2 \quad (1.20)$$

Uma versão com derivada descontínua pode ser proposta, com a vantagem de considerar somente os períodos em que o volume armazenado fosse inferior à meta.

$$\text{Minimizar} \quad \max_{i,t} \left[s(i, t) - x(i, t) \right] \quad \forall i \in \{1, 2, \dots, N\} \quad \forall t \in \{1, 2, \dots, T\} \quad (1.21)$$

1.4 Diferentes Horizontes de Planejamento e Intervalos de Discretização

Cada horizonte de planejamento requer diferentes tipos de análises. É necessário estudar e analisar as opções para o horizonte de planejamento e para o intervalo de discretização que melhor se adequam ao tipo de problema (modelagem, formulação, dimensão) que se deseja resolver.

A importância de certos parâmetros na modelagem varia de acordo com o horizonte de planejamento (Pereira et al. 1990). Por exemplo, a incerteza (estocasticidade) da vazão afluenta aos reservatórios tem maior importância no contexto plurianual de operação (longo prazo) quando é decidida a utilização de fontes térmicas e possui pouca importância no curto prazo, onde as previsões de afluência e demanda com razoável precisão são aceitas. Por outro lado, o tempo de traslado da água nas calhas fluviais entre os reservatórios tem importância no planejamento a curto prazo, mas em geral não afeta o planejamento a longo prazo.

Os parâmetros adotados no problema possuem um período de influência que determina o horizonte necessário para determinada análise do planejamento da operação. Por exemplo, a decisão sobre os estoques de água em reservatórios possui um período de influência longo, podendo alcançar um horizonte de vários anos; a falta de água nos reservatórios do sistema devido a uma seca severa pode durar vários meses; já as falhas nas unidades geradoras podem levar a cortes temporários do suprimento de energia nas horas de maior consumo.

Foi devido à impossibilidade de considerar todos os aspectos do problema, simultaneamente por um único modelo (Encina 2006), que a decomposição em etapas foi sugerida. Análises de longo prazo contemplam a estratégia de operação e a projeção de valores futuros de geração térmica e hidrelétrica do sistema, a possibilidade de desabastecimento de energia, contratos de suprimento de energia, etc. Análises de médio prazo estudam as possibilidades de vertimentos, deplecionamento dos reservatórios, programação da manutenção, etc. E análises de curto prazo abordam reservas operativas, restrições quanto à navegação, limites das redes de transmissão e distribuição, situações emergenciais, etc.

No planejamento da operação a longo prazo, em sistemas compostos por grandes reservatórios, com grande capacidade de regularização e crescimento anual acentuado da capacidade instalada, como é o caso do Brasil, é comum considerar a discretização mensal, que abrange um horizonte de alguns anos a frente. As afluências para um longo prazo possuem um alto grau de incertezas, fazendo necessária a consideração dessa estocasticidade. O planejamento a médio prazo geralmente abrange horizontes de alguns meses com discretização mensal ou semanal. Com o menor grau de incerteza das afluências aos reservatórios, nesta etapa as vazões podem ser tratadas como determinísticas. O planejamento de curto prazo tem como objetivo produzir um programa de geração que atenda às restrições operativas ao longo da próxima semana ou mês com discretização em dias ou bloco de horas. As vazões também têm tratamento determinístico nesta etapa.

No Brasil, a abordagem em vigor sugere a decomposição do problema nas seguintes etapas: longo prazo (modelo NEWAVE), médio prazo (modelo DECOMP) e curto prazo (modelo

DESSEM). Cada uma dessas etapas utiliza um horizonte compatível com as particularidades que se quer observar em um sistema hidrelétrico.

1.5 Revisão Bibliográfica

Existem muitos fatores que envolvem o Planejamento de Sistemas Hidrelétricos e é natural que várias outras abordagens sejam propostas. Uma breve revisão bibliográfica das principais abordagens propostas na literatura será apresentada a seguir.

A Programação Dinâmica (PD) é uma metodologia recursiva que pode ser aplicada tanto a problemas lineares quanto a problemas não-lineares e possui algumas variações. A PD consiste em dividir o período de planejamento em estágios e a melhor decisão (em cada estágio) é determinada de acordo com o estado em que o sistema se encontra. Satisfazendo o princípio da otimalidade de Bellman (Bellman 1957), o processo de otimização se baseia no conhecimento prévio das possibilidades e suas implicações. A desvantagem é a necessidade da discretização em estados, ocasionando um esforço computacional que cresce exponencialmente com o número de variáveis de estado consideradas.

A Programação Dinâmica Estocástica (PDE) obedece ao processo de otimização descrito sobre a PD, mas a decisão em cada estágio é obtida com base na distribuição de probabilidades dos estados em cada estágio. Este é um método adotado para a solução do problema de planejamento da operação quando existe estocasticidade das afluências. A “maldição da dimensionalidade” impede a utilização da PDE em problemas que apresentam a necessidade de se trabalhar com muitas usinas individualizadas.

Na década de 80, o planejamento da operação no Brasil era realizado utilizando a PDE e quatro subsistemas equivalentes: Norte, Nordeste, Sudeste/Centro-Oeste e Sul, sendo cada subsistema formado por um grande reservatório de energia, com volume equivalente à somatória da energia armazenada em cada reservatório da região. Devido à dificuldade causada pela dimensão do problema, a PDE trabalhava com um reservatório equivalente por vez. Isto porque, se cada reservatório fosse discretizado em cem intervalos e a vazão afluente a cada reservatório fosse discretizada em dez intervalos, para o caso de quatro reservatórios, seriam estudados um trilhão de estados em cada estágio. A ampliação do sistema de transmissão e a necessidade de interligação entre os subsistemas, ocasionaram um aumento no número de combinações de estados operativos, tornando a metodologia inviável computacionalmente (Kligerman 2009).

Desde então, o Operador Nacional do Sistema Elétrico (ONS) adota a Programação Dinâmica Dual Estocástica (PDDE)(Pereira & Pinto 1985), metodologia incorporada no modelo de

otimização NEWAVE (Costa et al. 1993, CEPEL 2007) desenvolvido pelo Centro de Pesquisas em Energia Elétrica (CEPEL) para o planejamento de longo prazo. As variáveis de decisão são a geração hidrelétrica, a geração térmica e o intercâmbio de energia entre os subsistemas. O objetivo é minimizar o valor esperado do custo da operação (custo presente do combustível e custo futuro da água) para todo o período de planejamento. As funções de custo futuro informam para os modelos de outras etapas (Figura 1.8) o impacto da utilização da água armazenada nos reservatórios. A PDDE é um método que trata a Programação Dual Estocástica (PDE) de forma analítica e propõe uma solução para o problema da “maldição dimensionalidade” através da redução da discretização dos estados de cada reservatório equivalente e da aproximação das funções de custo esperado em cada estágio por funções lineares por partes. O método representa um avanço no estado da arte, mas é computacionalmente custoso, e as premissas e simplificações da modelagem não permitem o tratamento de todas as incertezas e imprecisões do modelo (Kligerman 2009). E mesmo sendo o modelo em vigor a vários anos, ainda apresenta problemas: “O modelo Newave tem demonstrado preocupante imprevisibilidade e volatilidade, além de elevada vulnerabilidade à variação da afluência e extrema sensibilidade às mudanças nas hipóteses e premissas adotadas sobre oferta, demanda, custo do déficit, taxa de retorno e segurança sistêmica, entre outros.” (Pedrosa & Lopes 2007).




Figura 1.8: Abordagem em vigor (CEPEL 2003).

A solução apresentada pelo NEWAVE é desagregada a usinas individualizadas pelo modelo de planejamento de médio prazo, DECOMP (CEPEL 2004). Ou seja, o DECOMP decide o

quanto será produzido por cada usina de geração do sistema, a partir das funções de custo esperado futuro, disponibilizadas pelo NEWAVE, minimizando o custo da operação para todo o horizonte de planejamento. Baseado em um modelo de decomposição matemática linear, o modelo representa o primeiro mês com discretização semanal e vazões previstas, e no restante do período utiliza uma árvore de possibilidades (cenários de vazões) para representação da aleatoriedade das vazões. O modelo DESSEM (CEPEL 2003), de curto prazo, é responsável pela programação diária da operação. Nele são consideradas um grande conjunto de restrições, como tempo de viagem entre as barragens e limites de fluxo nas linhas de transmissão. O objetivo é minimizar o custo total da operação, determinando o despacho ótimo para a programação diária do sistema hidrotérmico.

O artigo (Pereira Junior 2005) sugere a atuação independente dos subsistemas brasileiros com a metodologia dos modelos NEWAVE e DECOMP para criar um ambiente comercial mais competitivo e de operação mais eficiente.

A PDE também foi utilizada em outros trabalhos da literatura (Yeh 1985, Stedinger et al. 1984). Em (Ferrero et al. 1998), é proposto um algoritmo baseado em programação dinâmica, de dois estágios, para sistemas com múltiplos reservatórios. Durante cada iteração, os possíveis estados dos reservatórios são restritos aos estágios vizinhos (próximo e anterior). O resultado é comparado com o algoritmo de programação dinâmica estocástica (Sherkat et al. 1985). Neste, um reservatório é otimizado por vez, assumindo uma operação fixa para os demais reservatórios; o procedimento se repete até que a convergência seja obtida. Em (Marcato 2002) foi proposto um modelo híbrido com usinas individualizadas nos primeiros estágios e agregação em subsistemas equivalentes posteriormente. O trabalho (Dias et al. 2010) utiliza o algoritmo de fechos convexos para modelar as funções de custo futuro da programação dinâmica estocástica no problema do planejamento da operação hidrotérmica. Um algoritmo de processamento paralelo também é proposto para contornar o alto esforço computacional do problema, ressaltando a importância da paralelização de código para a solução do problema de planejamento da operação de longo prazo. Uma comparação (Zambelli et al. 2006) entre modelos determinísticos e estocásticos para o planejamento hidrotérmico a longo prazo sugeriu-se que os modelos determinísticos podem ser mais atrativos, uma vez que os esforços computacionais são muito mais elevados na abordagem estocástica.

Dentre os trabalhos que utilizam outros métodos de programação matemática para a resolução do problema destaca-se o modelo de otimização a usinas individualizadas HydroMax (Cicogna & Soares 2005, Cicogna 2003), baseado em um algoritmo determinístico de fluxos em rede não-linear com arcos capacitados. A modelagem proposta abrange a representação do pro-

blema de planejamento energético em horizontes de médio e longo prazos, com estudos baseados nos subsistemas brasileiros. A técnica baseia-se no tratamento de dois problemas: termelétrico e hidrelétrico. A solução do Despacho Econômico Termelétrico (Cicogna 1999) fornece o custo termelétrico mínimo para atendimento de uma dada geração termelétrica, que será utilizado pelo problema de despacho hidrelétrico. No problema hidrelétrico, cada nó da rede representa o comportamento de uma usina hidrelétrica durante um intervalo de tempo. Os arcos da rede representam o volume armazenado nos reservatórios e a defluência das usinas em cada intervalo de tempo. A vazão incremental que chega a uma usina em determinado intervalo é tratada como uma injeção no nó. A equação de equilíbrio de fluxo de cada nó (Figura 1.9) representa a equação de balanceamento (Equação 1.9) da formulação do problema. As restrições operacionais são representadas pelas canalizações dos arcos da rede.




Figura 1.9: Representação da equação de balanceamento.

Divide-se o conjunto de arcos em básicos (representando as variáveis dependentes do problema) e não-básicos (representando as variáveis independentes do problema). O conjunto de arcos básicos forma uma estrutura de árvore e, ao se introduzir um arco não-básico à esta árvore, forma-se um ciclo. A partir da rede hidráulica, o HydroMax utiliza a técnica do Gradiente Reduzido (cálculo da direção de caminhada baseado no gradiente da função-objetivo reduzido ao espaço das variáveis não-básicas) (Luenberger 1984) para a obtenção da solução ótima. Os arcos do ciclo e suas respectivas derivadas informam o que acontece com a função-objetivo quando o fluxo passa pelo ciclo, e a partir disso é possível obter uma direção de caminhada. Este modelo de fluxos em redes foi anteriormente proposto utilizando direções de primeira ordem (Carvalho & Soares 1987, Carneiro et al. 1990), com informações do gradiente da função objetivo; direções de segunda ordem (Oliveira & Soares 1995), com informações do gradiente e da matriz Hessiana da função-objetivo; e com implementação utilizando orientação a objetos (Cicogna 1999). Outras abordagens semelhantes (Rosenthal 1981, Dembo & Klinecicz 1981) também utilizaram modelos de fluxo em redes não-linear com capacidade nos arcos.

Na mesma linha de pesquisa, o modelo de planejamento energético ODIN (Toscano 2009) trata a estocasticidade das vazões afluentes de forma indireta, por meio de um previsor de vazões afluentes e de um otimizador a usinas individualizadas. A cada intervalo, o modelo fornece as decisões de despacho hidrotérmico por usina. Comparações são realizadas com o modelo NEWAVE.

Em (Catalão, Mariano, Mendes & Ferreira 2009, Catalão, Pousinho & Mendes 2009) o planejamento da operação de sistemas hidrelétricos é formulado como um problema de otimização quadrática determinística a usinas individualizadas, com função-objetivo quadrática e um conjunto linear de restrições de igualdade e desigualdade. A matriz Hessiana do problema é indefinida logo, não há garantia de ótimo global. Os estudos foram realizados com subsistemas hidrelétricos em cascata portugueses. Os pacotes de otimização *Xpress-MP* e *MINUS* foram utilizados para a resolução do problema.

Em (Zambon 2008) é proposto o sistema Hidroterm de suporte à decisão, formado pelos modelos Hidro (otimiza o sistema não-linear com as usinas individualizadas e aproveitando ao máximo a capacidade hidrelétrica instalada), Term (otimiza o despacho térmico e intercâmbios entre os subsistemas), Hidroterm Iterativo (processo iterativo entre os modelos Hidro e Term) e Hidroterm Unificado (formulação unificada). Os modelos de otimização foram escritos através do *software* de otimização *GAMS*. O modelo SolverSin (Lopes 2007) foi desenvolvido para o planejamento da operação de sistemas hidrotérmicos também utilizando pacotes de otimização não-linear, além da agregação das hidrelétricas brasileiras em subsistemas.

Diversas técnicas de inteligência artificial também têm sido utilizadas no problema de planejamento. Dentre as propostas, um Algoritmo Genético (Leite et al. 2006, Leite et al. 2002) aplicado ao sistema hidrelétrico brasileiro, com abordagem determinística a médio e longo prazos. Os testes foram realizados em dois subsistemas da região Sudeste: um com 19 usinas com reservatório e outro com 35 usinas (19 anteriores mais 16 usinas fio d'água). Os volumes armazenados nos reservatórios de cada usina em cada período de tempo foram considerados como variáveis de decisão do modelo. Os mesmos autores propuseram um Algoritmo Genético Híbrido com operador genético baseado no método do gradiente (Leite & Carvalho 2006).

Outras propostas de Algoritmos Genéticos foram aplicadas ao problema hidrotérmico a curto prazo (Zoumas et al. 2004, Orero & Irving 1998) e no estudo da expansão do sistema (Park et al. 2000). A operação a curto prazo também foi o foco de propostas que utilizaram métodos de Programação Evolutiva (Sinha et al. 2003) e *Simulated Annealing* (Wong & Wong 1994).

Hibridizações foram propostas com Algoritmo Genético e *Simulated Annealing* (Li & Wei 2008) e Algoritmo Genético e técnicas de caos (Cheng et al. 2008). No primeiro artigo, o

Improved Genetic Algorithm-Simulated Annealing (IGA-SA) foi testado em um sistema com três reservatórios na China, num período de 12 meses. Comparações foram realizadas entre o IGA-SA com técnicas de Programação Dinâmica, Algoritmo Genético e *Simulated Annealing*; o IGA-SA obteve o melhor desempenho. O segundo artigo, também foi aplicado a um sistema na China e obteve desempenho melhor que a Programação Dinâmica e um Algoritmo Genético padrão. O trabalho de (Ferreira & Silva 2011) também realiza comparações entre um Algoritmo Genético e o *Simulated Annealing* na resolução do problema hidrotérmico aplicado a dois sub-sistemas brasileiros de 7 e 14 usinas hidrelétricas. Neste trabalho, o objetivo era minimizar o custo da complementação térmica, penalizando soluções ineficazes. Os autores demonstraram a aplicabilidade das abordagens propostas ao problema.

Todas as propostas apresentadas até aqui abordaram o problema, explicitamente, com um único objetivo. Os trabalhos que abordam o problema de planejamento tratando simultaneamente múltiplos objetivos são apresentados a seguir.

O trabalho de (Ko et al. 1992) comparou o Método das ε -restrições ao Método das Ponderações (Seção 2.2.3) no problema com múltiplos objetivos aplicado a um sistema de reservatórios. Foram avaliados quatro objetivos: maximizar a energia total produzida, maximizar a energia assegurada, maximizar a mínima defluência para abastecimento de água e maximizar a confiabilidade de satisfazer as necessidades de abastecimento de água a jusante. Na média, o Método das ε -restrições se mostrou mais eficiente, porém o Método das Ponderações obteve melhores resultados quando se considerou um grande número de objetivos. Em outro trabalho semelhante (Barros et al. 2003), o modelo de planejamento hidrelétrico foi linearizado e resolvido com técnicas de programação linear através da soma ponderada de seis objetivos.

Um Algoritmo Genético foi proposto (Jothiprakash & Shanti 2009) com o objetivo de minimizar as somas do quadrado do déficit mensal de irrigação e o desvio quadrado do volume do reservatório em relação ao volume mensal desejado; os dois objetivos foram ponderados. Os resultados foram comparados com um modelo de PDE, que obteve maior déficit de irrigação. O Algoritmo Genético conseguiu satisfazer esta demanda de melhor forma e obteve melhor desempenho. Um Algoritmo Genético similar foi desenvolvido anteriormente (Jothiprakash & Shanti 2006) pelos mesmos autores, sem os fatores de ponderação na função objetivo.

Um algoritmo de Otimização por Enxame de Partículas com mutação elitista, o *Elitist-Mutated Particle Swarm Optimization* (EMPSO) foi proposto com a ponderação dos múltiplos objetivos de um sistema de reservatórios (Kumar & Reddy 2007). Os objetivos considerados foram geração hidrelétrica e irrigação (este, com maior prioridade, obteve um peso maior). O algoritmo, após testado em um sistema hipotético, foi aplicado a um sistema real na Índia. Os

mesmos autores aplicaram o algoritmo MOGA (*Multiobjective Genetic Algorithm*) (Seção 3.3), considerando explicitamente os objetivos de irrigação e geração hidrelétrica em outro trabalho (Reddy & Kumar 2006). Os resultados ofereceram muitas alternativas em uma única execução do algoritmo, proporcionando flexibilidade de decisão ao operador.

O Algoritmo Genético NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) (Seção 3.3) foi modificado com a inserção de soluções aleatórias durante as iterações e aplicado em problemas testes e ao problema de planejamento hidrotérmico (Deb & Gupta 2006). O NSGA-II também foi aplicado ao estudo da operação de duas usinas com reservatórios em Taiwan (Chang & Chang 2009), maximizando a eficiência do uso da água dos reservatórios e minimizando o risco de falta de energia. O algoritmo obteve várias soluções práticas e alternativas para uma tomada de decisões.

Um Algoritmo Genético Multiobjetivo Macro-Evolucionário (MMGA) foi implementado (Chen et al. 2007) para otimizar um sistema com múltiplos objetivos em Taiwan. A macro-evolução evita a convergência prematura durante o processo seletivo e melhora a capacidade do Algoritmo Genético em lidar com problemas multiobjetivo através da diversificação do conjunto de soluções. Os objetivos envolviam demanda de água e geração hidrelétrica. O MMGA obteve melhor espalhamento quando comparado ao NSGA-II.

Os algoritmos MOPSO (Otimização por Enxame de Partículas, Seção 3.3) e NSGA-II foram analisados na operação do sistema de reservatórios do Rio São Francisco (Nascimento et al. 2007), com os objetivos de maximizar a energia gerada e o volume final dos reservatórios. Como os dois algoritmos foram propostos originalmente para busca irrestrita, foram aplicadas excessivas penalidades nas soluções infactíveis, conduzindo o algoritmo a selecionar somente as soluções viáveis. Os testes contemplaram um horizonte de 12 meses, para as usinas de Três Marias, Sobradinho e Itaparica. O MOPSO mostrou-se mais consistente na determinação da Fronteira de Pareto que o NSGA-II. As soluções do algoritmo NSGA-II concentraram-se mais na região que maximizou a energia gerada pelo sistema.

O algoritmo NSGA-II foi utilizado novamente em uma abordagem proposta com formulação irrestrita (Scola et al. 2011b). Os testes contemplaram um sistema com 5 usinas hidrelétricas brasileiras, com os objetivos de maximizar a geração média ao longo do ano e reduzir o pico de demanda de recursos energéticos não-renováveis. Primeiro, uma modificação nos limitantes inferiores dos reservatórios foi imposta ao final de cada intervalo, garantindo que o reservatório seja reabastecido com a afluência que chega, descontando a defluência mínima. Uma modificação semelhante nos limitantes superiores também foi introduzida. Um novo conjunto de variáveis de decisão foi escolhido: frações (Equações 1.22 e 1.23) dos volumes permitidos mensalmente,

segundo os novos limitantes, ao invés da quantidade de água armazenada mensalmente no reservatório. Com os novos limitantes modificados, garante-se que a vazão turbinada é sempre maior que a defluência mínima. A mesma idéia foi anteriormente aplicada a uma única usina hidrelétrica (Scola et al. 2011a).

$$x(i, t) = x_{min}(i, t) + \alpha(i, t) \cdot (x_{max}(i, t) - x_{min}(i, t)) \quad (1.22)$$

$$\alpha(i, t) \in [0, 1] \quad (1.23)$$

Um Sistema de Apoio à Decisão (SAD) é proposto (Kligerman 2009) com a integração de interface, sistema gerenciador da base de dados, modelo de otimização e modelo de apoio à decisão multicritério. O objetivo é sistematizar o processo decisório no planejamento da operação energética. Abordou-se um problema bi-critério, com a consideração do custo total da operação e da segurança energética. Na primeira etapa, um conjunto completo de soluções para o SAD é fornecido por um modelo de otimização com base em cenários de afluência previstos, em que a aleatoriedade observada no histórico de afluições é condicionada às condições antecedentes ao início do estudo. Deste conjunto, são selecionadas as soluções não-dominadas. Na segunda etapa, o decisor tem acesso às informações externas (tendências econômicas e climáticas), que permitem selecionar, dentre as soluções eficientes, um subconjunto de soluções aderentes a estas informações. Para este subconjunto de soluções é utilizado um método de apoio à decisão para determinação da decisão a ser adotada. O autor implementou um protótipo para o SAD. Para cada cenário de afluência previsto, utilizou o modelo DECOMP (CEPEL 2004) (múltiplas execuções) em sua modalidade determinística, como modelo de otimização, com objetivo de minimizar o custo total da operação. Para consideração do critério de segurança, é calculado, para cada solução, o risco de que o montante de geração térmica associado seja inferior ao adequado. Este risco consiste no número de cenários hidrológicos para os quais o montante de geração térmica, para a solução em questão, é menor que a recomendada. Determina-se então, as soluções não-dominadas que passarão por um processo de refinamento e análise interativa. As soluções mais aderentes às informações externas serão avaliadas e classificadas de acordo com o método PROMETHEE (Brans & Vinke 1985), no qual o decisor fornece um peso e elege uma função de preferência para cada critério. Este apoio à decisão multicritério foi implementado através de funções desenvolvidas em EXCEL. Como resultado, obtém-se o custo máximo de despacho para a utilização de geração térmica.

Os trabalhos de (Labadie 2004), (Yeh 1985) e (Farhat & El-Hawary 2009) apresentam revisões do estado da arte da Operação de Sistemas Hidrotérmicos. Apesar do considerável número

de pesquisas, a área ainda é promissora para novos trabalhos.

As abordagens desta tese foram propostas com o intuito de contribuir para o estudo deste problema. As análises abordam tanto aspectos do ponto de vista da Otimização Multiobjetivo, como aproximação da Fronteira de Pareto e dispersão das soluções, quanto aspectos operacionais das soluções obtidas, como regularização das vazões afluentes e geração hidrelétrica. A proposição de duas Metaheurísticas Evolutivas – Algoritmos Genéticos, método clássico e extensivamente aplicado aos problemas de otimização; e Evolução Diferencial, o estado da arte dos Algoritmos Evolutivos – para a resolução do Problema de Planejamento Hidrelétrico, permite a realização de novos estudos e comparações. Com foco no Sistema Brasileiro, os algoritmos propostos se diferenciam de outros trabalhos da literatura: uma proposta diferente das apresentadas para Algoritmo Genético e uma nova abordagem com a Evolução Diferencial. Do ponto de vista da Otimização Multiobjetivo Evolutiva, as abordagens contribuem ao tópico apontado como um dos desafios mais promissores de pesquisas para os próximos anos na área (Coello 2005): a aplicação em problemas reais fortemente restritos.

Otimização Multiobjetivo

Este capítulo apresenta os conceitos e definições relativos a Otimização Multiobjetivo que serão utilizados nas abordagens propostas, motivando o estudo e tratamento dos problemas de otimização explicitamente com múltiplos objetivos.

Muitos problemas do mundo real apresentam um conjunto de objetivos a serem otimizados. Na maioria das vezes estes objetivos são conflitantes, ou seja, a melhoria em um objetivo causa deterioração em outro. Atualmente, o enfoque Multiobjetivo encontra aplicações em qualquer área: problemas de planejamento de produção, transporte, alocação, gerenciamento de recursos (elétricos, hídricos, etc.), dentre outros.

No planejamento hidrelétrico, a maximização da geração hidrelétrica e a minimização da complementação térmica no período analisado contrapõem-se com a maximização dos volumes dos reservatórios. A decisão de minimizar a complementação térmica, sem qualquer outra restrição, ocasiona o deplecionamento dos reservatórios. Por outro lado, a decisão de manter os reservatórios cheios resulta em menor geração hidrelétrica e, conseqüentemente, maior complementação térmica para atendimento da demanda. Desta maneira, existe a necessidade do desenvolvimento de técnicas e procedimentos que permitam o tratamento simultâneo de todos os objetivos do problema. Esta é a tarefa da Otimização Multiobjetivo.

No tratamento de múltiplos objetivos, podem surgir problemas devido (Clímaco et al. 2003):

1. ao conflito entre as funções-objetivo, já que não existe uma solução que otimize simultaneamente todas as funções.
2. à incomensurabilidade entre as funções-objetivo, que não podem ser reduzidas a uma unidade de medida comum.
3. à incerteza resultante de conhecimentos imprecisos ou insuficientes e da informação de preferências do decisor numa realidade multidimensional.

A consideração de modelos de Otimização Multiobjetivo refletem melhor uma realidade complexa e possibilita a exploração de uma gama maior de soluções alternativas.

2.1 Definições

Matematicamente, um problema Otimização Multiobjetivo pode ser definido como o problema de encontrar um vetor de variáveis de decisão ω que satisfaça as restrições:

$$\Omega = \{\omega \in \mathbb{R}^n \mid M(\omega) \leq 0, \quad N(\omega) = 0, \quad \omega_{min} \leq \omega \leq \omega_{max}\} \quad (2.1)$$

e otimize¹ a função vetorial $F(\omega)$, cujos elementos representam as funções-objetivo (Osyczka 1985):

$$\text{Minimizar} \quad F(\omega) = [f_1(\omega), f_2(\omega), \dots, f_m(\omega)] \quad m \geq 2 \quad (2.2)$$

$$\text{Sujeito a} \quad \omega \in \Omega \quad (2.3)$$

Também, $\Lambda = \{\lambda \in \mathbb{R}^m \mid \lambda = F(\omega)_{\omega \in \Omega}\}$ é definida como a região factível correspondente para o espaço das funções-objetivo. A Figura 2.1 ilustra um exemplo de mapeamento do espaço das soluções no espaço das funções-objetivo no caso bidimensional.




Figura 2.1: Mapeamento do espaço das soluções no espaço das funções-objetivo.

Otimizar significa encontrar valores aceitáveis para as funções-objetivo para uma tomada de decisão; por $F(\omega)$ ser um vetor, se quaisquer componentes de $F(\omega)$ competirem, não existirá uma solução única para o problema e sim um conjunto de soluções de compromisso (*trade-offs*).

¹Serão apresentadas definições para o problema de minimização; definições para o problema de maximização são análogas.

Desta maneira, o conceito de Pareto²-otimalidade deve ser utilizado para a caracterização e obtenção das soluções.

Uma solução Pareto-ótima (ou não-dominada, não-inferior, eficiente) é aquela na qual uma melhora em um dos objetivos resulta em degradação de outro(s). No exemplo bidimensional da Figura 2.2, o conjunto de soluções Pareto-ótimas está representado entre os pontos A e B . As soluções C e D são Pareto-ótimas. Uma melhora no objetivo f_1 resulta em degradação do objetivo f_2 , isto é, $f_{1C} < f_{1D}$ e $f_{2C} > f_{2D}$.




Figura 2.2: Conjunto das soluções Pareto-ótimas.

O espaço de busca Ω é parcialmente ordenado no sentido de que duas soluções arbitrárias são relacionadas de duas possíveis maneiras: ou uma domina a outra ou nenhuma delas domina (Figura 2.3) (Abraham & Jain 2005). Exemplo: Se $F : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ é a função vetorial de um problema de minimização, existem três possibilidades:

1. Sejam ω_K e $\omega_L \in \Omega$, tais que, $F(\omega_K) = (2, 7)$ e $F(\omega_L) = (4, 9)$.
Então $F(\omega_K) \preceq F(\omega_L)$ (ω_K domina ω_L).
2. Sejam ω_P e $\omega_Q \in \Omega$, tais que, $F(\omega_P) = (5, 8)$ e $F(\omega_Q) = (1, 6)$.
Então $F(\omega_P) \succeq F(\omega_Q)$ (ω_P dominado por ω_Q).
3. Sejam ω_R e $\omega_S \in \Omega$, tais que, $F(\omega_R) = (3, 9)$ e $F(\omega_S) = (5, 7)$.
Então $F(\omega_R) \not\preceq F(\omega_S)$ e $F(\omega_R) \not\succeq F(\omega_S)$ (ω_R e ω_S são indiferentes).

²A noção de ótimo foi originalmente proposta por Francis Ysidro Edgeworth em 1881. Esta noção foi generalizada por Vilfredo Pareto em 1896. Embora alguns autores utilizem a denominação de Edgeworth-Pareto-otimalidade, neste projeto, é utilizado o termo Pareto-otimalidade.




Figura 2.3: Dominância de Pareto no espaço objetivo.

Estes conceitos podem ser formalizados pelas definições a seguir (Ferreira 1999, Sawaragi et al. 1985):

Definição 1. (Dominância de Pareto) Sejam ω_K e $\omega_L \in \Omega$. ω_K domina ω_L , $F(\omega_K) \preceq F(\omega_L)$ (problema de minimização), se e somente se:

$$\forall i \in \{1, 2, \dots, m\}, f_i(\omega_K) \leq f_i(\omega_L) \text{ e } \exists j \in \{1, 2, \dots, m\}, f_j(\omega_K) < f_j(\omega_L) \quad (2.4)$$

Ou seja, ω_K não é pior que ω_L em nenhum dos objetivos e é melhor em pelo menos um (Abraham & Jain 2005).

Definição 2. (Otimalidade de Pareto) Uma solução ω é Pareto-ótima se e somente se ω é não-dominada em relação à Ω , ou seja, nenhum vetor do espaço de busca domina ω .

A solução esperada é composta por um conjunto de pontos de equilíbrio, isto é, uma família de soluções consideradas equivalentes e superiores em relação ao restante das soluções.

Definição 3. O Conjunto Pareto-ótimo (P^*) é definido como:

$$P^* = \{\omega \in \Omega \mid \nexists \nu \in \Omega, F(\nu) \preceq F(\omega)\} \quad (2.5)$$

Definição 4. Dado um Conjunto Pareto-ótimo (P^*), a Fronteira de Pareto (FP^*) pode ser definida da seguinte forma:

$$FP^* = \{F(\omega) = [f_1(\omega), f_2(\omega), \dots, f_m(\omega)] \mid \omega \in P^*\} \quad (2.6)$$

Da mesma maneira que nos problemas de otimização monobjetivos, existe a possibilidade de problemas de Otimização Multiobjetivo apresentarem soluções Pareto-ótimas locais e globais. Em alguns casos, grande parte das soluções é atraída para as Fronteiras de Pareto locais. A Figura 2.4 ilustra a diferença entre uma Fronteira de Pareto global e uma local.

Definição 5. (Conjunto Pareto-ótimo local): Se para todo ω , membro de um conjunto P^* , não existir solução ν , $\|\nu - \omega\|_\infty \leq \varepsilon$, que domine qualquer solução pertencente a P^* , então as soluções pertencentes ao conjunto P^* constituem um Conjunto Pareto-ótimo local. ε é número positivo e ν é obtido através de uma perturbação numa pequena vizinhança de ω (Deb 1999).




Figura 2.4: Exemplo de Fronteiras global e local.

Definição 6. (Conjunto Pareto-ótimo global): Se não existir solução no espaço de busca que domine qualquer membro de um conjunto P^* , então as soluções pertencentes a P^* constituem o Conjunto Pareto-ótimo global (Deb 1999).

O objetivo é encontrar um conjunto de soluções não-dominadas com a maior diversidade possível, tanto no espaço das soluções (Ω) quanto no espaço dos objetivos (Λ) (Deb 1999), facilitando o conhecimento do problema e a escolha da solução mais adequada pelo decisor.

2.2 Métodos de Resolução

Desde 1896, quando o conceito “Pareto-ótimo” foi introduzido, várias técnicas para resolução de problemas de Otimização Multiobjetivo, tradicionais ou alternativas, tem sido desenvolvidas.

Dado que um problema de Otimização Multiobjetivo pode apresentar infinitas soluções não comparáveis entre si, torna-se evidente a necessidade de critérios adicionais para se chegar a uma solução final. Estes critérios são fornecidos por um decisor, que busca selecionar uma solução que proporcione uma relação de compromisso adequada entre os objetivos do problema (Ferreira 1999).

Os métodos de resolução podem ser classificados de acordo com o momento em que o decisor aplica seus critérios (Ferreira 1999): Métodos a-Priori, Métodos a-Posteriori e Métodos Iterativos.

2.2.1 Métodos a Priori

Nos Métodos a Priori (Figura 2.5), as preferências do decisor (processo de decisão) são definidas antes da resolução (processo de otimização). O problema multiobjetivo original é transformado em problemas mais simples, que podem ser resolvidos através de métodos conhecidos. A desvantagem desses métodos é que características desejáveis a uma solução são raramente conhecidas antecipadamente. Alguns destes métodos são apresentados a seguir.




Figura 2.5: Processos de otimização e decisão: abordagem a priori.

- Método Lexicográfico

O decisor deve listar os objetivos em ordem decrescente de importância $\{f_1, f_2, \dots, f_m\}$.

A primeira função-objetivo da lista é otimizada no espaço de busca e este resultado é

considerado como uma restrição na otimização da segunda função; e assim por diante. Generalizando:

$$\begin{array}{ll} \text{Minimizar} & f_j(\omega) \\ \text{Sujeito a} & \omega \in \Omega_j \end{array}$$

onde $\Omega_j = \{\omega \mid \omega \in \Omega_{j-1}, \omega = \operatorname{argmin}(f_{j-1})\}$ e $\Omega_0 = \Omega$. Uma desvantagem é que a solução final é muito sensível à ordenação dos objetivos.

- Método baseado em Limitantes

O decisor deve seleccionar um objetivo de preferência f_i , $i \in \{1, 2, \dots, m\}$, e indicar limitantes para os demais objetivos f_j , $j \in 1, 2, \dots, m$, $i \neq j$. Formalmente:

$$\begin{array}{ll} \text{Minimizar} & f_i(\omega) \\ \text{Sujeito a} & l_j \leq f_j(\omega) \leq L_j \quad \forall j \neq i \\ & \omega \in \Omega \end{array}$$

Especificar l_j e L_j de modo que o problema continue factível e que torne a solução satisfatória ao decisor pode ser difícil.

- Método da realização das metas

Associa-se um conjunto de metas ao conjunto de objetivos. A formulação do problema permite que os objetivos se encontrem acima ou abaixo das metas, esta imprecisão (ou folga) é controlada por um vetor de coeficientes de pesos $p = [p_1, p_2, \dots, p_m]$.

$$\begin{array}{ll} \text{Minimizar} & \gamma \\ \text{Sujeito a} & f_i(\omega) - \gamma p_i \leq f_i^* \\ & \omega \in \Omega \\ & \gamma \in \mathbb{R} \end{array}$$

$[f_1^*, f_2^*, \dots, f_m^*]$ definem a solução-meta e o vetor p define a direção de busca da solução-meta ao espaço factível das funções (Λ) . A solução (única) do problema não é necessariamente Pareto-ótima. Soluções Pareto-ótimas são geralmente obtidas quando as metas não são atingidas.

2.2.2 Métodos Iterativos

Os Métodos Iterativos (Figura 2.6) são mais elaborados. As informações sobre preferências (processo de decisão) são passadas pelo decisor durante a resolução do problema (processo de otimização). O decisor especifica e ajusta suas preferências ao mesmo tempo em que aprende, pois nem sempre é possível indicar preferências a priori devido à complexidade do problema. Algumas vantagens são: não existe a necessidade de conhecimento a-priori sobre o problema; por ser um processo de aprendizagem, o decisor pode entender melhor o problema; como o decisor faz parte da busca, uma solução pode ser aceita com maior possibilidade. Por outro lado, a solução depende do comportamento e conhecimento do decisor e da maneira que ele gerencia suas preferências. Alguns destes métodos são apresentados a seguir.




Figura 2.6: Processos de otimização e decisão: abordagem iterativa.

- Método de Geoffrion, Dyer e Feinberg

Este método é destinado a resolução de problemas convexos, do tipo:

$$\begin{array}{ll}
 \text{Minimizar} & U[f_1(\omega), f_2(\omega), \dots, f_m(\omega)] \\
 \text{Sujeito a} & \omega \in \Omega
 \end{array}$$

onde: Ω é convexo, $[f_1, f_2, \dots, f_m]$ são funções convexas sobre Ω e $U : \Lambda \rightarrow \mathbb{R}$ é uma função convexa crescente sobre Λ , que reflete as preferências do decisor em relação aos m objetivos. Como U não é totalmente conhecida, algumas informações devem ser fornecidas pelo decisor durante o processo.

- Método STEM

Este método é um procedimento iterativo destinado à resolução de problemas lineares:

$$\begin{array}{ll} \text{Minimizar} & C\omega \\ \text{Sujeito a} & A\omega \leq b \\ & \omega \geq 0 \end{array}$$

onde $C \in \mathbb{R}^{m \times n}$, $A \in \mathbb{R}^{l \times n}$ e $b \in \mathbb{R}^l$. Inicia-se, com a resolução de m problemas lineares, formados por cada um dos objetivos separadamente. O decisor deve classificar cada solução encontrada (valores das funções-objeto) como satisfatória ou insatisfatória, quando comparada com uma solução utópica. Se todos os objetivos forem satisfatórios, o algoritmo é encerrado. Caso contrário, um ou mais objetivos, classificados como satisfatórios, devem ser relaxados, com o intuito de melhorar os valores dos outros objetivos.

2.2.3 Métodos a Posteriori

Nos Métodos a Posteriori (Figura 2.7), busca-se gerar (processo de otimização) o Conjunto Pareto-ótimo, ou parte dele, para que depois, o decisor escolha uma solução de compromisso dentre todas as alternativas disponíveis, de acordo com algum critério ou preferência (processo de decisão). Alguns destes métodos são apresentados a seguir.




Figura 2.7: Processos de otimização e decisão: abordagem a posteriori.

- Método das Ponderações

Este método baseia-se na transformação do problema multiobjetivo em vários problemas monobjetivo, com a variação dos elementos do vetor $v \in \mathbb{R}^m$ tal que $v_i \geq 0$ e $\sum_{i=1}^m v_i = 1$.

Se $[f_1, f_2, \dots, f_m]$ são funções convexas, dado um vetor de pesos v , o Método das Ponderações consiste na resolução do problema:

$$\begin{array}{ll} \text{Minimizar} & \sum_{i=1}^m v_i f_i(\omega) \\ \text{Sujeito a} & \omega \in \Omega \end{array}$$

O método é útil na geração de subconjuntos de soluções de acordo com as “preferências” indicadas pelo vetor de pesos v . No caso de funções não-convexas, algumas porções do conjunto Pareto-ótimo podem não ser geradas.

- Método das ε -restrições

Baseado na minimização do objetivo de maior prioridade, transformando os outros objetivos em restrições de desigualdade. O método consiste na resolução de vários problemas, variando convenientemente os limitantes ε_j , $j = \{1, 2, \dots, m\}$:

$$\begin{array}{ll} \text{Minimizar} & f_i(\omega) \\ \text{Sujeito a} & f_j(\omega) \leq \varepsilon_j \quad \forall i \neq j \\ & \omega \in \Omega \end{array}$$

É possível gerar o Conjunto Pareto-ótimo mesmo para Λ não-convexo, caso em que o Método das Ponderações pode falhar. Uma dificuldade encontrada é a definição de valores para ε_j que garanta uma solução factível.

- Método Simplex Multiobjetivo

Este método é restrito à resolução de problemas lineares do tipo:

$$\begin{array}{ll} \text{Minimizar} & C\omega \\ \text{Sujeito a} & A\omega \leq b \\ & \omega \geq 0 \end{array}$$

onde $C \in \mathbb{R}^{m \times n}$, $A \in \mathbb{R}^{l \times n}$ e $b \in \mathbb{R}^l$. Os objetivos podem ser tratados simultaneamente, sem a necessidade de utilização de técnicas de escalarização. A região factível Ω tem a forma poliédrica, portanto, possui um número finito de ponto extremos. Assim o método Simplex Multiobjetivo “caminha” de um ponto extremo Pareto-ótimo a outro, até que todo o Conjunto de Pareto, formado por pontos extremos Pareto-ótimo e faces Pareto-ótimas, esteja caracterizado.

- Algoritmos Evolutivos

Os Algoritmos Evolutivos mais tradicionais podem ser classificados como métodos a posteriori, pois tendem a gerar um conjunto de pontos uniformemente distribuídos para a representação do Conjunto Pareto-ótimo. Esta abordagem, aplicada a resolução de problemas de Otimização Multiobjetivo será apresentada e discutida na Seção 3.3 do próximo capítulo.

Este capítulo apresentou os conceitos fundamentais da Otimização Multiobjetivo, com a classificação dos métodos de resolução utilizados para resolução deste tipo de problema. A próxima Seção discute alguns Algoritmos Evolutivos com a motivação para aplicação em problemas multiobjetivo.

Algoritmos Evolutivos

O objetivo deste capítulo é motivar a utilização dos Algoritmos Evolutivos na resolução dos problemas de otimização, com a apresentação das Metaheurísticas utilizadas pelas abordagens propostas neste trabalho. Uma revisão bibliográfica sobre a Otimização Multiobjetivo Evolutiva também será apresentada na Seção 3.3.

Algoritmos Evolutivos são procedimentos computacionais para a resolução de problemas, resultantes da aplicação de técnicas heurísticas baseadas na seguinte sequência básica: realização de reprodução com herança genética, introdução de variações aleatórias, promoção de competição e seleção de indivíduos de uma dada população. Isto é feito através de processos iterativos, onde cada iteração é chamada de geração. Esse processo é repetido um determinado número de vezes, tornando-os capazes de promover a busca por soluções em um enorme espaço de possibilidades, de maneira muito flexível (Knowles et al. 2008).

Os Algoritmos Evolutivos trabalham com uma população formada por um conjunto de indivíduos, ou seja, possíveis soluções para o problema. Durante as gerações, esta população é avaliada. Os mais adaptados tendem a ser selecionados e podem sofrer modificações em suas características através de cruzamentos (*crossover*) e mutações, gerando descendentes; finalmente os mais adaptados passam para a próxima geração, resultando em indivíduos cada vez mais aptos, enquanto os demais tendem a desaparecer.

A função de adaptação permite atribuir a cada elemento do espaço de busca um valor que é usado como medida de desempenho. Em problemas de otimização, esta função incorpora todos os aspectos presentes na função-objetivo. A codificação dos indivíduos e a definição da função de adaptação ou *fitness* são as etapas mais importantes do algoritmo, mas o desempenho do processo evolutivo também depende de parâmetros como: tamanho da população, probabilidade de aplicação dos operadores genéticos, critérios dos operadores de seleção e condição de parada.

A população inicial (da primeira geração) pode ser formada por indivíduos aleatórios ou

incorporar conhecimento a priori sobre o problema. Alguns indivíduos podem ser reinicializados durante as gerações, nos casos de queda da diversidade ou diminuição da taxa de melhoria.

Em problemas de otimização com restrições, a codificação adotada pode fazer com que indivíduos modificados sejam ineficazes. Nestes casos, cuidados especiais devem ser tomados na definição da codificação e dos operadores (Bäck et al. 2000b). Os operadores evolutivos dependem diretamente da definição do espaço de busca e da codificação do problema.

Embora possam parecer simplistas do ponto de vista biológico, estes algoritmos são suficientemente complexos para fornecer mecanismos de busca adaptativos, eficientes e robustos. Algumas características (Knowles et al. 2008) são frequentemente apontadas para dar suporte à aplicação dos Algoritmos Evolutivos na resolução de determinados problemas: desempenho e eficiência (têm a capacidade de encontrar soluções competitivas ou em melhor tempo computacional, do que outros métodos conhecidos), aplicabilidade e acessibilidade (são aplicáveis a quase todos os problemas de otimização) e favorabilidade (podem resolver problemas que não possuíam soluções conhecidas).

Para o desenvolvimento das abordagens propostas nesta tese, a princípio, optou-se pelo Algoritmo Genético, por se tratar de um método clássico. Foi um dos primeiros Algoritmos Evolutivos propostos na literatura e é facilmente adaptado a qualquer tipo de problema, além de ter sido extensivamente aplicado nas diversas áreas da engenharia. A escolha da Evolução Diferencial se deu por se tratar de um Algoritmo Evolutivo representante do estado da arte, com desempenho superior em diversos tipos de problemas (Storn & Price 1997) e por não existir nenhuma aplicação ao problema em estudo - Planejamento Hidrelétrico e Otimização Multiobjetivo.

Em (Goldberg 1989, Michalewicz 1996, Price et al. 2005), são expostos mais detalhes sobre as duas abordagens apresentadas neste capítulo, com apresentação de conceitos teóricos e definições. Nas Seções 3.1 e 3.2, são discutidas, brevemente, características de cada uma das abordagens; maiores detalhes serão dados no Capítulo 4 com a apresentação das abordagens propostas. Na Seção 3.3, é apresentada uma revisão bibliográfica com os principais Algoritmos Evolutivos aplicados na resolução de problemas de Otimização Multiobjetivo.

3.1 Algoritmos Genéticos

O trabalho pioneiro de J. H. Holland nos anos 70, com a publicação de seu livro, *Adaptation in Natural and Artificial Systems*, consolidou a contribuição dos Algoritmos Genéticos (Goldberg 1989) para a ciência e para as aplicações na área de engenharia. Desde então, os trabalhos de

pesquisa neste campo vêm crescendo consideravelmente (Man et al. 1996).

Algoritmos Genéticos são algoritmos de otimização baseados em uma estratégia de busca paralela, estruturada e estocástica por soluções com maior desempenho. Apesar de aleatória, a busca é direcionada, pois explora informações históricas para encontrar novas soluções. Um conjunto de operações é necessário para que, dada uma população, se consiga gerar populações sucessivas com melhores desempenhos que as anteriores.

Operadores unários, como a mutação, criam um novo indivíduo partindo de um único genitor, mantendo a diversidade genética da população. Operadores de ordem mais elevada, como o cruzamento, geram novos indivíduos através da recombinação de características de dois ou mais indivíduos genitores (herança). O cruzamento é considerado o operador genético predominante, por isso é aplicado com probabilidade maior que a mutação.

Quanto maior for a probabilidade de cruzamento, mais rapidamente novas soluções são introduzidas na população; porém, valores muito altos podem resultar em perda de soluções com boa aptidão. Com valores muito baixos, o algoritmo pode tornar-se muito lento. Os cruzamentos são realizados com o intuito de que os novos indivíduos (filhos) contenham partes boas dos indivíduos antigos (pais), de maneira que a nova população seja melhor que a anterior. Entretanto, é bom deixar uma parte da antiga população sobreviver para a próxima geração. Uma baixa probabilidade de mutação evita que as soluções fiquem estagnadas em um valor (busca local). Um valor muito alto torna a busca essencialmente aleatória. Se não houver mutação, a descendência é gerada imediatamente após o cruzamento.

Os métodos de seleção podem ser determinísticos ou probabilísticos. A ideia básica é privilegiar indivíduos com valores de *fitness* mais elevados. Para garantir que os melhores indivíduos não desapareçam da população pela manipulação dos operadores genéticos, eles podem passar para a próxima geração através da seleção elitista.

Uma forma geral e simplificada de um Algoritmo Genético é apresentada a seguir.

```
Procedimento AlgoritmoGenetico(populacao, GERACOES)
{
    inicializa(populacao);
    avaliacao(populacao);
    para t = 1 até GERACOES
    {
        selecionaPais(populacao);
        cruzamento(populacao);
        mutacao(populacao);
        avaliacao(populacao);
    }
}
```

3.2 Evolução Diferencial

A Evolução Diferencial (Price et al. 2005) foi apresentada como uma versão melhorada dos Algoritmos Genéticos, com o intuito de se resolver os problemas de otimização mais rapidamente (Storn & Price 1997). É uma metaheurística desenvolvida para ser um método de busca paralela, direta e estocástica (Storn & Price 1997).

A Evolução Diferencial gera um novo indivíduo através da adição da diferença ponderada entre duas soluções a uma terceira solução (Figura 3.1). A ponderação previne duplicações de soluções existentes; esta operação é considerada como uma mutação. A solução mutada (*donor*) é então combinada com outra solução pré-determinada, a solução *target*, para gerar a solução *trial*. Esta combinação corresponde ao cruzamento (*crossover*) e tem a finalidade de aumentar a diversidade das soluções mutadas ao mesmo tempo que incorpora soluções boas de gerações anteriores. É importante ressaltar que, na versão original do algoritmo, cada solução presente na população atual deve ser usada uma vez como *target*. Ou seja, toda solução da população deve ser utilizada no cruzamento e, por consequência, na seleção. Caso a solução *trial* forneça um valor de *fitness* melhor que aquele associado à respectiva solução *target*, esta última dará lugar à primeira na próxima geração (critério guloso). Esta operação corresponde à seleção.




Figura 3.1: Mutação, Cruzamento e Seleção da Evolução Diferencial.

Uma das vantagens da Evolução Diferencial é a necessidade de poucos parâmetros de controle para os operadores, os quais têm seus valores ajustados de maneira relativamente simples. Além dos típicos parâmetros (número de indivíduos e número de gerações), somente dois parâmetros são adotados: *CR* (para o cruzamento, controla a influência dos pais na geração dos filhos) e *F* (para a mutação).

Além disso, a própria distribuição das soluções no espaço de busca determina o tamanho do passo e a direção de busca de cada indivíduo. Esta é considerada a principal vantagem da Evolução Diferencial (Mezura-Montes et al. 2008).

Uma forma geral e simplificada de um algoritmo de Evolução Diferencial é apresentada a seguir.

```
Procedimento EvolucaoDiferencial(populacao, GERACOES)
{
    inicializa(populacao);
    avaliacao(populacao);
    para t = 1 até GERACOES
    {
        mutacao(populacao);
        cruzamento(populacao);
        selecionaTargetTrial(populacao);
        avaliacao(populacao);
    }
}
```

3.3 Algoritmos Evolutivos e Otimização Multiobjetivo

Atualmente, existem mais de 30 técnicas de Programação Matemática para resolução de problemas de Otimização Multiobjetivo. Entretanto, estas técnicas tendem a gerar somente um elemento do Conjunto Pareto-ótimo a cada execução (Coello 2002). Algumas técnicas exigem o conhecimento prévio do problema, uma especificação detalhada ou a indicação de preferências, o que quase sempre não é possível. Outras, fazem a combinação dos múltiplos objetivos através de pesos. Na prática, diferentes objetivos não são mensuráveis na mesma unidade ou na mesma escala. Além disso, a combinação dos vários objetivos podem ocasionar a perda de soluções potenciais e pequenas mudanças nos pesos pode resultar em soluções totalmente diferentes (Knowles et al. 2008).

Já os Algoritmos Evolutivos permitem que vários membros do Conjunto Pareto-ótimo sejam encontrados em uma única execução do algoritmo, sem a necessidade da realização de uma série de execuções, separadamente (Coello 2005). Tratar problemas com múltiplos e conflitantes objetivos com Algoritmos Evolutivos pode ser útil e mais próximo da realidade, o que fez a Otimização Multiobjetivo Evolutiva crescer rapidamente (Knowles et al. 2008). Hoje, a Otimização Multiobjetivo Evolutiva é mais do que um ramo da área da Computação Evolutiva; representa um grande passo na resolução de problemas computacionais (Knowles et al. 2008).

Desde a apresentação do primeiro algoritmo, em meados dos anos 80, várias abordagens evolutivas, principalmente de Algoritmos Genéticos, têm sido propostas para a resolução de problema de Otimização Multiobjetivo. As principais abordagens são apresentadas a seguir.

As primeiras abordagens populacionais foram propostas com o intuito de diversificar a busca, mas combinavam ou agregavam todos os objetivos em um único, como em algumas técnicas de Programação Matemática. Pesquisadores da área de Otimização Multiobjetivo Evolutiva demonstraram pouco interesse na proposição de novos métodos utilizando esta idéia (Coello & Cortés 2005a).

Outras propostas surgiram, mas o conceito de dominância de Pareto não foi diretamente incorporado ao processo de seleção. O primeiro algoritmo proposto que representa esta abordagem é:

- VEGA - *Vector Evaluated Genetic Algorithm* (Schaffer 1984)

O algoritmo VEGA se diferencia de um simples algoritmo genético somente pelo modo como a seleção é realizada. Cada indivíduo da população é formado pelo código genético (binário) e pelo seu desempenho em cada uma das funções-objetivo (separadamente). Através de seleção proporcional ao *fitness* pelo método *Roulette Whell*, sub-populações são formadas, uma para cada função-objetivo. A nova população é constituída pela junção das sub-populações e aplicação dos operadores de cruzamento e mutação. VEGA não incorpora diretamente o conceito de Pareto-ótimo. Algumas desvantagens do algoritmo são: tendência em selecionar indivíduos com grande desempenho em apenas um dos objetivos, ignorando indivíduos com desempenho médio em todos os objetivos, impedindo uma boa caracterização do Conjunto Pareto-ótimo; incapacidade de produzir certas porções da Fronteira de Pareto; não tem mecanismo explícito para manutenção de diversidade; não necessariamente produz indivíduos globalmente não-dominados.

Tendo por base as desvantagens apresentadas pelo algoritmo VEGA, foram discutidas outras abordagens para lidar com problemas multiobjetivo (Goldberg 1989), considerando o conceito de Pareto-dominância para classificação dos indivíduos da população. Caracterizados pelo uso de *fitness sharing* e *niching* para manutenção da diversidade, evitando a convergência para uma única solução, os seguintes algoritmos foram propostos:

- MOGA - *Multiobjective Genetic Algorithm* (Fonseca & Fleming 1993).

Foi a primeira abordagem a considerar o conceito de dominância na classificação das soluções. A classificação de um determinado indivíduo é igual a um, mais o número de

indivíduos da população corrente pelos quais ele é dominado. Dessa forma, todos os indivíduos não-dominados recebem classificação (*rank*) igual a um e a classificação máxima de um indivíduo dominado não excede o tamanho da população. A população é ordenada de acordo com a classificação recebida e a cada solução é atribuído um *fitness* preliminar (*raw fitness*) usando uma função linear ou exponencial, garantindo que soluções com melhor classificação possuam *fitness* melhores. Para manter a diversidade das soluções utilizou-se, para cada classificação, o método de formação de nichos (*niching*). Após a obtenção dos nichos, calcula-se o *fitness* compartilhado (*fitness sharing*) de cada solução, de acordo com a ordem de classificação. Desta forma as soluções que residem em um nicho menos ocupado terão melhor *fitness* compartilhado. Este método permite que soluções pouco representadas em cada *ranking* se destaquem. Por outro lado o *fitness* de compartilhamento não garante que as soluções de maior classificação terão pior desempenho que soluções de menor classificação. Os operadores de seleção, cruzamento e mutação são os usuais.

- NSGA - *Non-dominated Sorting Genetic Algorithm* (Srinivas & Deb 1994)

A principal característica do algoritmo NSGA é que, antes da seleção, os indivíduos são classificados em diferentes níveis de dominância (fronteiras de classificação). Primeiro, os indivíduos não-dominados presentes na população corrente são identificados. Estes indivíduos recebem um valor de *fitness dummy*, o que permite que tenham o mesmo potencial de serem selecionados. Depois, o compartilhamento de *fitness* (*fitness sharing*) é aplicado nos indivíduos da primeira fronteira, de maneira a penalizar seus respectivos *fitness*, baseado no número de indivíduos que compartilham a mesma vizinhança (o tamanho da vizinhança é controlado por um parâmetro, o raio de nicho); o intuito é a manutenção da diversidade da população. Então, os indivíduos da primeira fronteira são retirados da população para continuidade do processo de classificação dos indivíduos restantes nas respectivas fronteiras (os indivíduos da segunda fronteira recebem *fitness dummy* menor que os indivíduos da primeira fronteira, e assim por diante). Como os indivíduos da primeira fronteira têm os maiores valores de *fitness*, eles serão selecionados mais vezes que o resto da população, o que permite a busca por indivíduos não-dominados. O NSGA recebeu algumas críticas em relação à alta complexidade computacional de ordenação de não-dominância, à necessidade de especificar o parâmetro de compartilhamento e à falta de elitismo.

- NPGA - *Niched-Pareto Genetic Algorithm* (Horn et al. 1994)

O algoritmo NPGA apresenta um esquema de seleção por torneio baseado em Pareto-dominância, já que a relação de dominância estabelece uma ordem parcial, e emprega o compartilhamento de *fitness* (*fitness sharing*) para os casos em que o torneio encontra não-dominância. Os torneios obedecem aos seguintes critérios: dois indivíduos e um conjunto de comparação (em torno de 10% da população) são selecionados aleatoriamente. O vencedor é o indivíduo que não for dominado pelo conjunto de comparação. Se houver empate (ambos dominados ou ambos não-dominados), a análise passa a focar o número de indivíduos presentes no nicho em que se encontra cada indivíduo candidato. Vence o indivíduo que pertencer ao nicho menos populoso. Uma dificuldade é que o NPGA é muito sensível ao tamanho do conjunto de comparação do torneio: se o tamanho for muito grande, a população irá convergir prematuramente para apenas uma parte da Fronteira de Pareto; se for muito pequeno, a população final será formada por muitas soluções dominadas.

Com a introdução do conceito de elitismo nos Algoritmos Evolutivos Multiobjetivo, novos algoritmos foram apresentados:

- SPEA - *Strength Pareto Evolutionary Algorithm* (Zitzler & Thiele 1999)

O SPEA usa o critério de Pareto-dominância para a atribuição de *fitness* e seleção dos indivíduos. A cada geração, indivíduos da população corrente classificados como não-dominados são copiados para a população externa (arquivo). A atribuição de *fitness* é realizada em dois estágios: primeiro, um valor representando a força de Pareto (*strength*), é atribuído para cada indivíduo do arquivo (proporcional ao número de indivíduos da população corrente que por ele são dominados); depois, para cada indivíduo da população corrente é calculado um valor de *fitness* somando a força de cada indivíduo do arquivo que o domina. Esta estratégia reflete intuitivamente a idéia de preferir indivíduos próximos à Fronteira de Pareto e ao mesmo tempo, distribuídos ao longo da superfície de busca. A diversidade é mantida através de uma técnica de agrupamento chamada *average linkage method*. A seleção é realizada através de torneio binário com reposição. Alguns problemas encontrados no algoritmo são: indivíduos da população dominados pelos mesmos indivíduos do arquivo possuem *fitness* idênticos, portanto, se o arquivo contém um único elemento então todos os indivíduos terão o mesmo *fitness* (neste caso, o SPEA comporta-se como uma busca aleatória); pouca ou nenhuma informação pode ser extraída se muitos indivíduos são indiferentes (situação comum em problemas com mais de dois objetivos); o algoritmo de agrupamento pode destruir as soluções nas bordas da Fronteira de Pareto.

- SPEA2 - *Strength Pareto Evolutionary Algorithm 2* (Zitzler et al. 2001)

O algoritmo SPEA2 tenta contornar as dificuldades do SPEA. O novo algoritmo redefine a atribuição de *fitness*, o mecanismo de *crowding* e o mecanismo para a preservação da Fronteira de Pareto. As principais alterações são: a atribuição de *fitness* leva em consideração quantos indivíduos dominam e são dominados por cada indivíduo, considerando população corrente e arquivo; uma técnica baseada no k -ésimo vizinho mais próximo é usada para estimar a densidade, isto permite um método de busca mais preciso; o truncamento dos indivíduos do arquivo para preservação dos indivíduos da Fronteira de Pareto.

- PAES - *Pareto Archived Evolution Strategy* (Knowles & Corne 2000)

Os autores apresentam o algoritmo PAES que emprega uma busca local em três variantes: $(1+1)$, $(1+\lambda)$, $(\mu+\lambda)$. O algoritmo $(1+1)$ -PAES é composto por três partes: um gerador de soluções candidatas, que a cada geração produz uma única solução por mutação aleatória; uma função de aceitação das soluções candidatas e o arquivo de soluções não-dominadas. No $(1+\lambda)$ -PAES, a geração das λ soluções mutantes aumenta o problema de decisão. No caso $(\mu+\lambda)$ -PAES, os λ mutantes são gerados a partir das μ soluções selecionadas por torneio binário. O PAES utiliza um *grid* adaptativo para a manutenção da diversidade.

- NSGA-II - *Non-dominated Sorting Genetic Algorithm II* (Deb et al. 2000)

O NSGA-II é computacionalmente mais eficiente do que o NSGA, com destaque para a classificação das soluções em fronteiras. Passou a utilizar a técnica de comparação por *crowding*, um operador de comparação de aglomeração que prioriza as melhores fronteiras ou pontos que estão menos aglomerados, o que eliminou a necessidade de especificar um parâmetro de compartilhamento. Também utilizou o conceito de elitismo. Outro enfoque do NSGA2 está no estudo de problemas de Otimização Multiobjetivo restritos.

- NPGA 2 - *Niched Pareto Genetic Algorithm 2* (Erickson et al. 2001)

O algoritmo NPGA 2 foi proposto com o intuito de melhorar a dependência do NPGA em relação ao tamanho do conjunto de comparação. No NPGA 2 a classificação é baseada no grau (ou níveis) de Pareto-dominância.

- PESA - *Pareto Envelope-based Selection Algorithm* (Corne et al. 2000)

O algoritmo PESA trabalha com duas populações, uma principal (menor) e uma secundária (maior). Utiliza o mesmo *grid* adaptativo que o PAES, para a manutenção da diversidade. O mecanismo de seleção é baseado na medida de aglomeração (*crowding*) usada no *grid* e esta mesma medida é usada para decidir quais soluções devem ser

introduzidas na população secundária (soluções não-dominadas). A população externa é importante para o algoritmo pois está ligada à seleção e à manutenção de diversidade.

- MicroGA - *Micro-Genetic Algorithm for Multiobjective Optimization* (Coello & Toscano-Pulido 2001).

Micro-GA para Otimização Multiobjetivo é um Algoritmo Genético com uma população pequena e um processo de reinicialização. Soluções aleatórias são geradas e a partir delas, uma memória é construída. Parte da memória nunca sofrerá alteração e proverá a diversidade requerida pelo algoritmo. Outra parte, contendo as soluções não-dominadas, sofrerá mudanças a cada ciclo do micro-GA. A população, no início de cada ciclo é formada por indivíduos de ambas as memórias, ou seja, parte aleatória e parte evoluída. Operadores genéticos são realizados durante cada ciclo.

Além dos Algoritmos Genéticos, outras metaheurísticas foram aplicadas com sucesso aos problemas de Otimização Multiobjetivo:

Otimização por Enxame de Partículas A utilização da técnica de Enxame de Partículas (ou *Particle Swarm*) na resolução de problemas de Otimização Multiobjetivo é relativamente recente. Inspirada no comportamento coletivo, esta técnica já vinha obtendo bons resultados em uma variedade de problemas de Otimização Monobjetivo.

- MOPSO - *Multiobjective Particle Swarm Optimization* (Coello & Lechuga 2002)

Utiliza o conceito de Pareto-dominância para determinar a direção de vôo da partícula e mantém as soluções não-dominadas encontradas nas iterações anteriores em um repositório (arquivo histórico). O repositório é utilizado de maneira a guiar o vôo de outras partículas. Através dele cada partícula deve escolher um líder para guiar a busca. O uso de mecanismos globais de atração, combinados com este repositório motivaria a convergência para a Fronteira de Pareto global. A atualização do repositório é realizada considerando um sistema geograficamente definido em termos dos valores das funções-objetivo de cada partícula. Esta técnica é inspirada no arquivo externo do algoritmo PAES, discutido anteriormente. O número de partículas de um algoritmo de Enxame de Partículas é equivalente ao tamanho da população em um Algoritmo Genético. E o tamanho do repositório é utilizado para delimitar o número máximo de soluções não-dominadas que devem ser armazenadas; este parâmetro irá determinar a qualidade da Fronteira de Pareto produzida. O algoritmo proposto resolve somente problemas irrestritos.

- EMOPSO - *Efficient Multi-Objective Particle Swarm Optimizer* (Toscano-Pulido et al. 2007)

Para a seleção de soluções não-dominadas bem distribuídas, foram propostos três mecanismos: um grid adaptativo; uma forma relaxada de Pareto-dominância; e uma distribuição por hiperplano. A abordagem que obteve mais sucessos nos testes foi a distribuição por hiperplano. A idéia é selecionar um conjunto representativo de soluções não-dominadas distribuídas no hiperplano definido pelos valores mínimos dos objetivos. Seja k o número desejado de soluções não-dominadas. Então, o algoritmo seleciona as soluções que representam o valor mínimo de cada objetivo. Um hiperplano entre todas as soluções mínimas é computado. Depois o espaço é dividido em $k - 1$ regiões e no vértice de cada região uma linha perpendicular ao hiperplano é traçada. Finalmente o algoritmo aceita as soluções que estão mais próximas de cada linha. Também foi proposto um operador que altera a velocidade do vôo da partícula, com o intuito de evitar a convergência prematura e controlar a pressão seletiva. Além disso, a proposta trabalha com vários enxames ao mesmo tempo, o que resultou em bons resultados principalmente na presença de Fronteiras de Pareto desconexas. Um mecanismo que trata as restrições foi proposto.

Sistemas Imunológicos Artificiais Os Sistemas Imunológicos Artificiais surgiram a partir de tentativas de modelar e aplicar princípios imunológicos no desenvolvimento de novas ferramentas computacionais. O repertório é formado por anticorpos (possíveis soluções) que geram novos herdeiros (clones) com as mesmas características dos anticorpos-pai. Os clones evoluem por meio de operadores de maturação. Uma medida de afinidade é utilizada de forma a privilegiar a proliferação dos anticorpos mais adaptados ao ambiente.

- MISA - *Multiobjective Immune System Algorithm* (Coello & Cortés 2005b)

Os anticorpos foram representados por *strings* binárias que codificaram as variáveis de decisão do problema. Dominância e factibilidade das soluções foram utilizadas como medida de afinidade, para identificar soluções que mereciam ser clonadas. A mutação uniforme foi aplicada aos clones e mutação não-uniforme aos anticorpos “não tão bons”. Uma população externa armazena as soluções não-dominadas encontradas ao longo do processo de busca. Existe interação com a população externa para decidir quantos clones produzir, baseado num critério de aglomeração. O princípio de seleção clonal permite a busca local em diferentes direções ao longo da Fronteira de Pareto (exploração) através do processo de clonagem. A mutação aplicada aos

piores anticorpos desempenha a exploração de todo o espaço de busca.

- VAIS - *Vector Artificial Immune System* (Freschi & Repetto 2005)

Os anticorpos foram codificados por variáveis reais. Dominância e factibilidade das soluções foram utilizadas como medida de afinidade. Para cada solução não-dominada, a afinidade é igual a uma força (*strength*), como definida no SPEA2. Para as soluções dominadas, a afinidade é igual ao número de soluções que a dominam. Esta classificação resulta em um ordenamento parcial porque todas as soluções não-dominadas possuem afinidade menor que um e as soluções dominadas possuem afinidade maior que um. Todos os anticorpos são clonados. Quanto maior a afinidade do anticorpo-pai, menor a amplitude de mutação sofrida pelos clones. Os anticorpos não-dominados são armazenados na memória. Calcula-se a distância Euclidiana entre os anticorpos da memória, no espaço das funções-objetivo, com o intuito de obter uma Fronteira de Pareto uniformemente distribuída. Se o indivíduo gerado for infactível, ele é descartado. Se a infactibilidade ocorre após a aplicação do operador de mutação, reduz-se progressivamente a amplitude da mutação até que o clone se torne factível.

- omni-aiNet - *Artificial Immune Network for Omni-optimization* (Coelho & Von Zuben 2006)

Baseia-se na rede imunológica opt-aiNet (de Castro & Timmis 2002), com a incorporação de alguns mecanismos introduzidos pelo dopt-aiNet (de França et al. 2005). Além disso, o algoritmo contempla a resolução de problemas de otimização monobjetivo ou multiobjetivo, e unimodais ou multimodais. O algoritmo possui um repertório de anticorpos capaz de ajustar seu tamanho durante a execução do algoritmo, de acordo com um limiar de supressão pré-definido e um mecanismo de *grid* que controla o espalhamento das soluções no espaço de objetivos. Esta característica garante maior flexibilidade ao processo de busca, uma vez que o algoritmo ajusta o tamanho do repertório automaticamente, propiciando uma melhor alocação dos recursos computacionais. Inicia-se com a geração aleatória do repertório inicial, formado por anticorpos codificados por variáveis reais e representando uma solução do problema. Os principais passos do algoritmo são executados: clonagem, hipermutação polinomial, seleção e duplicação genética. A supressão e a inserção de novos anticorpos aleatoriamente gerados são realizadas segundo uma frequência definida pelo usuário. O repertório é ordenado em classes, de acordo com a qualidade de cada indivíduo. A qualidade é definida de acordo com o conceito de ϵ -dominância restrita, originalmente

proposta por (Deb & Tiwari 2005).

Evolução Diferencial A Evolução Diferencial é atualmente, uma das metaheurísticas mais populares na resolução de problemas de Otimização Monobjetivo. Devido a este sucesso, mais recentemente, pesquisadores têm tentado estender sua aplicação a outros tipos de problemas, como os de Otimização Multiobjetivo.

- PDE - *Pareto-Frontier Differential Evolution* (Abbass et al. 2001)

Abordagem baseada em Pareto-dominância, em que a população inicial e o parâmetro de mutação F são inicializados de acordo com uma distribuição gaussiana. Mutação e cruzamento são realizados somente entre as soluções não-dominadas de cada geração. Dentre estas, três soluções são escolhidas aleatoriamente (sendo uma para *target*) e os operadores clássicos são aplicados. A solução *trial* é colocada na população somente se dominar a solução *target* correspondente. Todas as soluções dominadas são removidas da população. Se o número de soluções não-dominadas exceder um limitante, a distância Euclidiana entre duas soluções é utilizada para remover da população soluções com a menor distância de vizinhança.

- PBDE - *Pareto-Based Differential Evolution* (Madavan 2002)

Neste trabalho, a Evolução Diferencial incorporou os mecanismos propostos anteriormente para o NSGA-II (ordenação não-dominada e classificação), além de uma abordagem de mutação e crossover semelhante à PDE. As soluções criadas formam uma nova população que é combinada com a população de pais para a escolha dos melhores indivíduos.

- NSDE - *Nondominated Sorting Differential Evolution* (Iorio & Li 2004)

Esta abordagem é uma modificação do NSGA-II. Os novos indivíduos são criados com os operadores clássicos da Evolução Diferencial.

- DEMO - *Differential Evolution for Multiobjective Optimization* (Robič & Filipič 2005)

A abordagem utiliza os operadores de mutação e crossover clássicos da Evolução Diferencial e modifica o mecanismo de seleção: se a nova solução (*trial*) domina a solução *target*, a nova solução substitui a solução original; se a solução *target* domina a nova solução, então a solução *trial* é descartada; caso contrário, a nova solução é adicionada à população. Então, o algoritmo aplica o mecanismo de ordenação não-dominada para truncar a população e manter fixo o número de indivíduos a cada geração.

O principal desafio, para qualquer abordagem, é minimizar a distância das soluções aproximadas geradas pelo Algoritmo Evolutivo do verdadeiro Conjunto Pareto-ótimo, maximizando a diversidade das soluções deste conjunto e evitando a perda de boas soluções durante o processo de otimização, através da implementação de operadores específicos para o problema multiobjetivo (Abraham & Jain 2005).

Métodos de Resolução Propostos

Na primeira parte do trabalho, são propostos dois Algoritmos Evolutivos para a resolução do problema de Planejamento Hidrelétrico, na formulação monobjetivo. O intuito é o estudo das abordagens propostas – Algoritmos Genéticos e Evolução Diferencial, aplicadas a forma mais “simples” do problema, antes da implementação do algoritmo para resolução da formulação com múltiplos objetivos.

Na segunda parte, são propostos dois algoritmos evolutivos para a resolução do problema em sua forma multiobjetivo, inspirados em alguns operadores do Algoritmo Genético NSGA-II (Deb et al. 2000), um dos algoritmos propostos na literatura com melhor desempenho na resolução de problemas de Otimização Multiobjetivo.

Na Seção 4.1 são apresentadas considerações sobre os algoritmos implementados, na formulação monobjetivo, Algoritmo Genético (hidroGA) e Evolução Diferencial (hidroDE). Na Seção 4.2 são descritos os operadores e funcionalidades específicos da formulação multiobjetivo, para o Algoritmo Genético (hidroNSGA) e para a Evolução Diferencial (hidroNSDE).

O desenvolvimento e as funcionalidades dos Algoritmos Evolutivos propostos para a resolução do problema de Planejamento Hidrelétrico foram implementados com a preocupação de respeitar as características físicas e operacionais do sistema.

4.1 Formulação Monobjetivo: hidroGA e hidroDE

Os componentes e as principais funcionalidades dos algoritmos monobjetivo propostos são descritos a seguir. Nas Seções 4.1.1 e 4.1.2, respectivamente, estão descritos os operadores exclusivos de cada um dos algoritmos hidroGA e hidroDE.

Codificação

Adotou-se a codificação real para a representação do problema. Um indivíduo k representa a vazão turbinada, $q_k(i, t)$, de cada usina em cada período de tempo, ou seja, cada indivíduo da população é uma matriz bidimensional (Figura 4.1).




Figura 4.1: Representação de um indivíduo da população.

Inicialização

O tamanho da população (TP) e o número de gerações (G) foram definidos empiricamente, de acordo com as análises (Capítulo 5) realizadas durante os testes. A inicialização de cada indivíduo da população é aleatória, ou seja, para cada usina e período de tempo, de cada indivíduo k , a vazão turbinada $q_k(i, t)$ é um número aleatório no intervalo $[u_{min}(i), q_{max}(i)]$.

Avaliação da População

Para cada indivíduo k da população:

1. para cada usina i com reservatório, o volume inicial $x_k(i, 1)$ é conhecido e fornecido antes do início da execução;
2. para cada usina i a fio d'água, considerou-se que $x_k(i, t) = x_{max}(i)$, $\forall t$ e a equação de balanceamento (Equação 1.9) se reduz a:

$$restr_k^{Fio}(i, t) = y(i, t) - q_k(i, t) - z_k(i, t) + \sum_{j \in \Omega_i} [q_k(j, t) + z_k(j, t)] \quad (4.1)$$

$$restr_k^{Fio}(i, t) = 0 \quad (4.2)$$

$$\forall t = 1, \dots, T$$

A vazão vertida foi interpretada como variável de folga: só ocorre se a vazão turbinada atingiu o limite máximo $q_{max}(i)$ e o reservatório também está no volume máximo $x_{max}(i)$.

Para cada indivíduo k da população, calcula-se:

1. $x_k(i, t)$ volume do reservatório¹ de cada usina para $t = 2$ até $T + 1$, utilizando a Equação 1.9. Considera-se o sentido das cascatas: de cima para baixo;
2. $u_k(i, t)$ vazão defluente de cada usina em cada período de tempo, utilizando a Equação 1.10;
3. $p_k(i, t)$ geração hidrelétrica de cada usina em cada período de tempo, utilizando as Equações 1.6, 1.7 e 1.8;
4. $H_k(t)$ geração hidrelétrica total em cada período de tempo, utilizando a Equação 1.5.

Operadores de Factibilização

Após a avaliação da população, faz-se a verificação da factibilidade das soluções em relação às restrições operacionais de volumes mínimo e máximo, vazão turbinada máxima e vazão defluente mínima (Equações 1.11, 1.12 e 1.13). Caso ocorra infactibilidade, operadores de factibilização são acionados.

A factibilização ocorre a tempo de simulação e também considera o sentido das cascatas: de cima para baixo. Usinas com reservatório e usinas a fio d'água possuem operadores diferentes.

Os operadores de cada tipo de usina, são descritos a seguir:

- Usinas com reservatório.

Para estas usinas, são realizadas as seguintes verificações de infactibilidade: se $q_k(i, t) > q_{max}(i)$, $u_k(i, t) < u_{min}(i, t)$, $x_k(i, t) < x_{min}(i)$ ou $x_k(i, t) > x_{max}(i)$.

Nesta etapa, também são realizadas verificações em relação à vazão vertida²: se $z_k(i, t) > 0$ e a usina poderia estar turbinando ou guardando no reservatório.

Primeiramente, são apresentados os pseudocódigos das funções utilizadas para verificação do vertimento e tratamento das infactibilidades.

¹Reservatório de acumulação.

²Não é uma infactibilidade, mas também foi tratada nesta etapa do algoritmo.

```

VerificarVertimentoReservatorio()
{
    // tenta guardar no reservatório o que está sendo vertido
    se (  $z_k(i, t) > 0$  e  $x_k(i, t+1) < x_{max}(i)$  )
    {
        se (  $x_k(i, t+1) + z_k(i, t) \frac{\Delta t}{10^6} < x_{max}(i)$  ) //  $\frac{\Delta t}{10^6}$  para conversão:  $m^3/s \rightarrow hm^3$ 
        {
             $z_k(i, t) = 0;$ 
        }
        senão
        {
             $z_k(i, t) = ( x_k(i, t+1) + z_k(i, t) \frac{\Delta t}{10^6} ) - x_{max}(i);$ 
        }
    }
}

```

```

VerificarVertimentoTurbinavel()
{
    // tenta turbinar o que está sendo vertido
    se (  $z_k(i, t) > 0$  e  $q_k(i, t) < q_{max}(i)$  )
    {
        se (  $q_k(i, t) + z_k(i, t) < q_{max}(i)$  )
        {
             $q_k(i, t) = q_k(i, t) + z_k(i, t);$ 
             $z_k(i, t) = 0;$ 
        }
        senão
        {
             $z_k(i, t) = q_k(i, t) + z_k(i, t) - q_{max}(i);$ 
             $q_k(i, t) = q_{max}(i);$ 
        }
    }
}

```

O tratamento das infactibilidades é realizado da seguinte forma:

```

se (  $q_k(i, t) > q_{max}(i)$  )
{
     $z_k(i, t) = q_k(i, t) - q_{max}(i);$  // diminui a vazão turbinada
     $q_k(i, t) = q_{max}(i);$ 
}

```

```

se (  $u_k(i, t) < u_{min}(i)$  )
{
     $q_k(i, t) = u_{min}(i);$  // aumenta a vazão turbinada
     $z_k(i, t) = 0;$ 
}

```

```

se (  $x_k(i, t+1) < x_{min}(i)$  )
{
    // primeiro verifica se está vertendo em t,
    // o que poderia guardar no reservatório em t+1
    se (  $z_k(i, t) > 0$  )
    {
        VerificarVertimentoReservatorio();
        // se ainda assim, continua inactivo
        se (  $x_k(i, t+1) < x_{min}(i)$  )
        {
            // diminui a vazão turbinada
            enquanto (  $x_k(i, t+1) < x_{min}(i)$  e  $q_k(i, t) > u_{min}(i)$  )
            {
                 $q_k(i, t) = fr * q_k(i, t);$     //  $fr \simeq 1,0$ 
            }
        }
    }
    senão
    {
        // diminui a vazão turbinada
        enquanto (  $x_k(i, t+1) < x_{min}(i)$  e  $q_k(i, t) > u_{min}(i)$  )
        {
             $q_k(i, t) = fr * q_k(i, t);$     //  $fr \simeq 1,0$ 
        }
    }
}

se (  $x_k(i, t+1) > x_{max}(i)$  )
{
    // primeiro verifica se é possível aumentar a vazão turbinada em t,
    // diminuindo o reservatório em t+1
    se (  $q_k(i, t) < q_{max}(i)$  )
    {
        // aumenta a vazão turbinada
        enquanto (  $x_k(i, t+1) > x_{max}(i)$  e  $q_k(i, t) < q_{max}(i)$  )
        {
             $q_k(i, t) = q_k(i, t) + fr * ( q_{max}(i) - q_k(i, t) );$     //  $fr \simeq 0$ 
        }
        // se ainda assim, continua inactivo
        se (  $x_k(i, t+1) > x_{max}(i)$  )
        {
            // aumenta a vazão vertida
             $z_k(i, t) = z_k(i, t) + ( x_k(i, t+1) - x_{max}(i) ) \frac{10^6}{\Delta t};$ 
        }
    }
    senão
    {
        // aumenta a vazão vertida
         $z_k(i, t) = z_k(i, t) + ( x_k(i, t+1) - x_{max}(i) ) \frac{10^6}{\Delta t};$ 
    }
}

```

Em relação ao vertimento, verifica-se a possibilidade de turbinar ou guardar em reservatório a vazão que está sendo vertida (ou apenas parte dela).

```

se (  $z_k(i, t) > 0$  )
{
  se (  $x_k(i, t+1) < x_{max}(i)$  )
  {
    VerificarVertimentoReservatorio();
    se (  $z_k(i, t) > 0$  e  $q_k(i, t) < q_{max}(i)$  )
    {
      VerificarVertimentoTurbinavel();
    }
  }
  senão se (  $q_k(i, t) < q_{max}(i)$  )
  {
    VerificarVertimentoTurbinavel();
  }
}

```

- Usinas a fio d'água.

Para estas usinas, são realizadas as seguintes verificações de infactibilidade: $q_k(i, t) > q_{max}(i)$, $u_k(i, t) < u_{min}(i, t)$, $restr_k^{Fio}(i, t) < 0$ ou $restr_k^{Fio}(i, t) > 0$.

As infactibilidades referentes à vazão turbinada máxima e à vazão defluente mínima:

```

se (  $q_k(i, t) > q_{max}(i)$  ) { ... }
se (  $u_k(i, t) < u_{min}(i)$  ) { ... }

```

têm o mesmo tratamento realizado no caso de usinas com reservatório.

Em relação ao vertimento, a única alternativa é verificar se a vazão que está sendo vertida (ou parte dela), pode ser alterada para vazão turbinada.

```

se (  $z_k(i, t) > 0$  )
{
  se (  $q_k(i, t) < q_{max}(i)$  )
  {
    VerificarVertimentoTurbinavel();
  }
}

```

O tratamento das demais infactibilidades é realizado da seguinte forma:

```

se (  $restr_k^{Fio}(i,t) > 0$  )
{
    // aumentar vazão turbinada ou vertida
    se (  $q_k(i,t) + z_k(i,t) + restr_k^{Fio}(i,t) \leq q_{max}(i)$  )
    {
         $q_k(i,t) = q_k(i,t) + z_k(i,t) + restr_k^{Fio}(i,t)$ ;
         $z_k(i,t) = 0$ ;
         $restr_k^{Fio}(i,t) = 0$ ;
    }
    senão
    {
         $z_k(i,t) = q_k(i,t) + z_k(i,t) + restr_k^{Fio}(i,t) - q_{max}(i)$ ;
         $q_k(i,t) = q_{max}(i)$ ;
         $restr_k^{Fio}(i,t) = 0$ ;
    }
}

se (  $restr_k^{Fio}(i,t) < 0$  )
{
    // se for possível zerar  $restr_k^{Fio}$  através
    // da diminuição das vazões turbinada e vertida
    se (  $q_k(i,t) + z_k(i,t) \geq -restr_k^{Fio}(i,t)$  )
    {
        // se diminuir  $z$  é suficiente para zerar  $restr_k^{Fio}$ 
        se (  $z_k(i,t) \geq -restr_k^{Fio}(i,t)$  )
        {
             $z_k(i,t) = z_k(i,t) + restr_k^{Fio}(i,t)$ ;
             $restr_k^{Fio}(i,t) = 0$ ;
            // verifica se o restante de  $z$  pode ser turbinado
            se (  $q_k(i,t) + z_k(i,t) \leq q_{max}(i)$  )
            {
                 $q_k(i,t) = q_k(i,t) + z_k(i,t)$ ;
                 $z_k(i,t) = 0$ ;
            }
            senão
            {
                 $z_k(i,t) = q_k(i,t) + z_k(i,t) - q_{max}(i)$ ;
                 $q_k(i,t) = q_{max}(i)$ ;
            }
        }
        senão // só diminuir  $z$  não é suficiente para zerar  $restr_k^{Fio}$ 
        {
            // se diminuir  $q$  além de  $z$ , não ocasionará outra infactibilidade
            se (  $q_k(i,t) + z_k(i,t) + restr_k^{Fio}(i,t) \geq u_{min}(i)$  )
            {
                 $q_k(i,t) = q_k(i,t) + z_k(i,t) + restr_k^{Fio}(i,t)$ ;
                 $z_k(i,t) = 0$ ;
                 $restr_k^{Fio}(i,t) = 0$ ;
            }
        }
    }
}

```

A cada alteração nos valores de $q_k(i, t)$ ou $z_k(i, t)$, para algum indivíduo k , na usina i , no tempo t , o indivíduo é reavaliado (atualização de restrições e equação de balanceamento). Isto inclui a reavaliação de todas as usinas a jusante de i .

Função de Desempenho

No algoritmo desenvolvido para a formulação monobjetivo, considerou-se a minimização do custo da complementação térmica penalizada como função de desempenho (*fitness*) de cada indivíduo. De forma geral, o sistema brasileiro explora intensamente a geração hidrelétrica, enquanto minimiza a necessidade de complementação com a geração térmica (Zambon 2008). Com o intuito de evitar o deplecionamento do volume final dos reservatórios na solução do problema, adotou-se um método de penalização da função-objetivo, através da combinação de dois objetivos: Equações 1.16 e 1.19 ou Equações 1.16 e 1.20. Esta penalização foi aplicada aos volumes dos reservatórios no último intervalo do horizonte de planejamento³.

A população é ordenada em ordem crescente segundo esta função (a função-objetivo do problema é de minimização).

Operadores de Uniformização

Operadores de uniformização dos volumes dos reservatórios das usinas a jusante também foram implementados. Sabe-se que as usinas a montante sofrem maior variação de volume por terem a função de regularizar o sistema (Soares & Carneiro 1991, Cicogna & Soares 2005). Para isto, verificam-se os melhores indivíduos da população após $G/2$ gerações. Caso o volume do reservatório da usina a jusante na cascata estiver, durante os intervalos de tempo, cheio ou apenas com pequenas oscilações, esta usina terá seu funcionamento a fio d'água durante o restante das iterações. Ou seja, $x_k(i, t) = x_{max}(i), \forall t = 1, \dots, T$. Este operador foi implementado utilizando uma informação já conhecida da operação em cascata com o intuito de acelerar o processo de convergência da solução.

Operador de Manutenção da Diversidade

A cada geração, todos os indivíduos infactíveis⁴ são substituídos por outros gerados aleatoriamente (reinicialização). Isto permite que outras regiões do espaço de busca possam ser exploradas. Além disso, outro operador para manutenção da diversidade das soluções é proposto: com a população ordenada, para cada solução $q_k(i, t)$, verificar se

³No caso multiobjetivo os objetivos são tratados simultaneamente, sem necessidade de penalização ou ponderação.

⁴Indivíduos que continuam infactíveis mesmo após passarem pelos Operadores de Factibilização.

$fitness(q_{k+1}(i, t)) - fitness(q_{k-1}(i, t)) < \epsilon$, ou seja, se as soluções $q_{k-1}(i, t)$ e $q_{k+1}(i, t)$ possuírem valores de função de desempenho suficientemente próximas, ambas são substituídas por novas soluções aleatórias (reinicialização), mantendo apenas a k -ésima solução na população.

As soluções finais são os melhores indivíduos das gerações, que evoluíram carregando fortes características e obtiveram os melhores desempenhos, ou seja, soluções factíveis com os melhores valores para a função-objetivo.

Os demais operadores de cada algoritmo são descritos nas seções a seguir.

4.1.1 Formulação Monobjetivo e Algoritmo Genético: hidroGA

Os operadores específicos do Algoritmo Genético são apresentados nesta seção. Diferentes operadores de cruzamento e mutação foram propostos com o intuito de balancear a exploração (busca local) com a exploração, na busca pelas melhores soluções.

Seleção

Todos os indivíduos que representam soluções factíveis podem ser selecionados. O processo de seleção é realizado através de torneio. Ou seja, duas soluções factíveis são selecionadas aleatoriamente para competirem; aquela que possuir o melhor *fitness* será escolhida para compor o conjunto dos pais.

Pares de pais são formados, aleatoriamente, com os indivíduos da seleção que passaram pelo torneio; estes pares podem passar pelo cruzamento e pela mutação, dependendo da probabilidade, *PC* e *PM* associadas aos operadores.

Cruzamento

O operador de cruzamento pode ou não ser acionado, dependendo da probabilidade a ele associada, *PC*. Para cada par, sorteia-se um número aleatório entre 0 e 1; se este número for menor que *PC* então o operador atua na formação dos filhos, caso contrário, filhos são cópias dos pais. O operador de cruzamento é aplicado nos pares selecionados (nas variáveis $q_k(i, t)$), sendo que cada par gera dois filhos. Os indivíduos filhos são avaliados e, se necessário, operadores de factibilização são aplicados. Uma comparação entre os indivíduos (dois pais e dois filhos) envolvidos no cruzamento é realizada; os dois melhores permanecem na população.

Sejam $q_{p_1}(i, t)$ e $q_{p_2}(i, t)$ dois indivíduos pais, selecionados para cruzamento. Dois diferentes tipos de cruzamento foram implementados: Cruzamento Aritmético e Cruzamento BLX-Alfa.

O Cruzamento Aritmético é definido como uma combinação linear conforme descrito a seguir (Equações 4.3 e 4.4). Para cada i, t , com 50% de probabilidade, $q_{f_1}(i, t) = q_{p_1}(i, t)$ e $q_{f_2}(i, t) = q_{p_2}(i, t)$, ou seja, os filhos recebem as mesmas características dos pais. E com 50% de probabilidade, para cada i, t , os filhos recebem as características combinadas:

$$q_{f_1}(i, t) = \alpha q_{p_1}(i, t) + (1 - \alpha) q_{p_2}(i, t) \quad (4.3)$$

$$q_{f_2}(i, t) = (1 - \alpha) q_{p_1}(i, t) + \alpha q_{p_2}(i, t) \quad (4.4)$$

onde α é um número aleatório pertencente ao intervalo $[0, 1]$. Em problemas de otimização com restrições, onde a região factível é convexa, se $q_{p_1}(i, t)$ e $q_{p_2}(i, t)$ pertencem à região factível, combinações convexas de $q_{p_1}(i, t)$ e $q_{p_2}(i, t)$ também são factíveis.

No Cruzamento BLX-Alfa (Equações 4.5 e 4.6), os dois descendentes resultantes são formados da seguinte maneira: para cada i, t , com 50% de probabilidade, $q_{f_1}(i, t) = q_{p_1}(i, t)$ e $q_{f_2}(i, t) = q_{p_2}(i, t)$, ou seja, os filhos recebem as mesmas características dos pais. E com 50% de probabilidade, para cada i, t , os filhos recebem as características combinadas:

$$q_{f_1}(i, t) = q_{p_1}(i, t) + \alpha_1(q_{p_2}(i, t) - q_{p_1}(i, t)) \quad (4.5)$$

$$q_{f_2}(i, t) = q_{p_1}(i, t) + \alpha_2(q_{p_2}(i, t) - q_{p_1}(i, t)) \quad (4.6)$$

onde α_1 e α_2 são números aleatórios pertencentes ao intervalo $[-\beta, 1 + \beta]$ e β pertence ao intervalo $[0; 0, 5]$. Os parâmetros α_1 , α_2 e β são responsáveis pelas características do operador, definindo as regiões nas quais os indivíduos filhos podem se situar: (i) para β igual a 0, este cruzamento se comporta como o Cruzamento Aritmético, ou seja, os filhos são gerados no intervalo entre os pais e (ii) para $\beta > 0$, o intervalo onde os filhos podem ser gerados se estende, diversificando as soluções.

É importante observar que as localizações das soluções geradas pelos operadores de cruzamento dependem da diferença entre os pais. Se esta diferença for pequena, a diferença entre os filhos também o será. Logo, se a diversidade na população for grande, é esperada uma grande diversidade na população da geração seguinte, garantindo a exploração de todo espaço de busca no início do processo evolutivo e focando a busca em uma determinada região à medida que as soluções convergem (Deb 2001).

Mutação

O operador de mutação pode ou não ser acionado, dependendo da probabilidade a ele associada, PM . A mutação é realizada nos indivíduos finais do cruzamento (os dois

melhores entre pais e filhos); é aplicada na variável $q_k(i, t)$. Para cada indivíduo, para cada usina i , para cada período de tempo t , sorteia-se um número aleatório entre 0 e 1. Se este número for menor que PM , então o operador atua no indivíduo, promovendo variação em sua posição i, t ; caso contrário, permanece como está. Dois tipos de mutação foram implementados.

A Mutação Uniforme considera uma direção de mutação d , aleatória e pertencente a $[-1, 1]$. O tamanho do passo α é um valor aleatório e pertencente a $[0, \frac{q_k(i, t)}{10}]$, ou seja, a mutação aumenta ou diminui a vazão turbinada em até 10% de seu valor atual.

A Mutação Não-Uniforme, especialmente desenvolvida para problemas de otimização com restrição e codificação em ponto flutuante (Michalewicz 1996), é um operador dinâmico destinado a melhorar o processo de busca. Podemos defini-lo da seguinte forma: seja $q_k(i, t) = [q_k(1, 1) \dots q_k(1, T); q_k(2, 1) \dots q_k(2, T); \dots ; q_k(N, 1) \dots q_k(N, T)]$ um indivíduo k e suponha que o elemento $q_k(2, 4)$ (vazão turbinada pela usina 2 no período 4) foi selecionado para mutação. O novo elemento resultante da mutação é, com 50% de probabilidade cada:

$$q'_k(2, 4) = \begin{cases} q_k(2, 4) + \Delta(g, a - q_k(2, 4)) & \text{ou} \\ q_k(2, 4) - \Delta(g, q_k(2, 4) - b) \end{cases} \quad (4.7)$$

onde, neste caso, $[a, b]$ equivale a $[u_{min}(2), q_{max}(2)]$. A função $\Delta(g, y)$ retorna um valor no intervalo $[0, y]$ tal que a probabilidade de $\Delta(g, y)$ ser próximo de zero aumenta à medida que g aumenta ($g = 1, \dots, G$). Esta propriedade faz com que este operador inicialmente explore o espaço de busca de forma mais ampla, nas gerações iniciais, e localmente, em gerações avançadas. (Michalewicz 1996) propõe a seguinte função: $\Delta(g, y) = y \cdot (1 - r^{(\frac{1-g}{G})^5})$, onde r é um número aleatório no intervalo $[0, 1]$.

Os indivíduos resultantes, após cruzamento e mutação, são avaliados e, se necessário, operadores de factibilização são aplicados.

4.1.2 Formulação Monobjetivo e Evolução Diferencial: hidroDE

A seguir, é feita a apresentação dos operadores específicos (Figura 3.1) da Evolução Diferencial.

Mutação

Para cada solução factível $q_k(i, t)$ (*target*) da população, para $k = 1, \dots, TP$, uma nova

solução $q'_k(i, t)$ é gerada, através da mutação:

$$q'_k(i, t) = q_{r_1}(i, t) + F(q_{r_2}(i, t) - q_{r_3}(i, t)) \quad (4.8)$$

onde $r_1, r_2, r_3 \in 1, \dots, TP$ são índices mutuamente distintos e diferentes de k ; e F é a constante de mutação, real e pertencente ao intervalo $[0, 2]$. F pode ser interpretada como o passo a ser dado na direção $q_{r_2}(i, t) - q_{r_3}(i, t)$. Esta é a proposta clássica da Evolução Diferencial.

Outra forma de mutação também foi implementada. A idéia é semelhante à Otimização por Enxame de Partículas (*Particle Swarm*) (Kennedy & Eberhart 1995):

$$q'_k(i, t) = q_k(i, t) + F(q_{best}(i, t) - q_k(i, t)) + F \cdot (q_{r_1}(i, t) - q_{r_2}(i, t)) \quad (4.9)$$

Desta forma, a mutação carrega informações sobre a solução atual $q_k(i, t)$, sobre a melhor solução $q_{best}(i, t)$, além de uma variação aleatória $q_{r_1}(i, t) - q_{r_2}(i, t)$.

Cruzamento

Seja $q_k(i, t)$ a solução *target* e $q'_k(i, t)$ a respectiva solução mutada (*donor*). A solução *trial* $q''_k(i, t)$ é obtida através do cruzamento:

$$q''_k(i, t) = \begin{cases} q'_k(i, t), & \text{se } r_{it} \leq CR \text{ ou } (i, t) = (l_i, l_t) \\ q_k(i, t), & \text{se } r_{it} > CR \text{ e } (i, t) \neq (l_i, l_t) \end{cases} \quad (4.10)$$

onde $i = 1, \dots, N$, $t = 1, \dots, T$, r_{it} é um número aleatório entre $[0, 1]$ (distribuição uniforme), $CR \in [0, 1]$ é a constante de cruzamento e (l_i, l_t) são valores aleatoriamente escolhidos para (i, t) que garante que $q''_k(i, t)$ recebe pelo menos uma componente de $q'_k(i, t)$.

Seleção

Se o *fitness* de $q''_k(i, t)$ é melhor que o *fitness* de $q_k(i, t)$, então $q_k(i, t) = q''_k(i, t)$, caso contrário, $q_k(i, t)$ passa para a próxima geração.

4.2 Formulação Multiobjetivo: hidroNSGA e hidroNSDE

O foco desta tese é o estudo da formulação multiobjetivo para o problema de Planejamento Hidrelétrico. Novos operadores inspirados no algoritmo NSGA-II (Deb et al. 2000, Deb et al. 2002) são propostos e apresentados a seguir. Os algoritmos propostos, hidroNSGA e hidroNSDE, reuniram algumas das principais características propostas no NSGA-II e já conheci-

das como importantes ou necessárias na resolução de problemas de Otimização Multiobjetivo, incorporando novas funcionalidades necessárias para a resolução do Problema de Planejamento Hidrelétrico.

Para a resolução do problema, admite-se que não são conhecidas informações de preferências entre os objetivos, de forma que o algoritmo deve gerar alternativas para a posterior escolha do decisor. Portanto, algumas metas importantes em Otimização Multiobjetivo devem ser atingidas: encontrar um conjunto de soluções que esteja o mais próximo possível do Conjunto Pareto-ótimo, com a maior diversidade possível no espaço dos objetivos e no espaço das variáveis.

A seguir, são descritas as funcionalidades comuns aos dois algoritmos. Alguns operadores são semelhantes aos propostos para a formulação monobjetivo (Seção 4.1): Codificação, Inicialização, Avaliação da População, Operadores de Factibilização e Operadores de Uniformização.

Após a inicialização, avaliação e factibilização (se necessário), a cada indivíduo da população P_g associa-se uma classificação (*rank*) e uma distância de aglomeração (*crowding distance*):

Classificação da População: abordagem não-dominada

O processo de classificação irá separar cada indivíduo em diferentes categorias (ou diferentes fronteiras) de acordo com os critérios de dominância (Seção 2.1). O processo inicia-se pela primeira fronteira (melhores indivíduos). Na próxima etapa, a segunda fronteira é obtida. Isto se repete até que não sobrem mais indivíduos na população fora de alguma fronteira (Figura 4.2). Esta classificação, ou *rank*, será utilizada nos operadores que serão definidos a seguir.




Figura 4.2: Ordenação da população.

Optou-se por considerar a factibilidade das soluções durante a classificação. Ou seja, todas as soluções infactíveis receberão o mesmo e o maior valor de *rank*. O intuito é que estas

soluções, que mesmo passando pelos operadores de factibilização continuam infactíveis, sejam menos favorecidas durante o processo seletivo.

Distância de Aglomeração

Utilizou-se a distância de aglomeração (*crowding distance*) (Deb et al. 2000), para privilegiar pontos extremos ou pontos mais espalhados pelas diferentes fronteiras. A ideia é utilizar a distância de cada indivíduo k aos indivíduos mais próximos ($k - 1$) e ($k + 1$), formando um cubóide (Figura 4.3).




Figura 4.3: Cálculo da distância de aglomeração.

Esta abordagem não necessita de nenhum parâmetro definido pelo usuário para a manutenção da diversidade da população.

Novamente, todos os indivíduos factíveis da população atual P_g são selecionados para criação de uma população de pais de tamanho TP . A maneira como esta população de pais é formada está apresentada nas próximas seções, pois é diferente para cada abordagem: hidroNSGA e hidroNSDE.

A população de pais passará por operadores de mutação e cruzamento (também descritos nas próximas Seções), para a formação da população de filhos Q_g , de tamanho TP . A combinação da população atual P_g com a população de filhos Q_g formará a população auxiliar R_g . Esta população de tamanho $2TP$ será classificada de acordo com a abordagem não-dominada descrita acima. Além disso, a cada indivíduo da população auxiliar R_g associa-se a distância de aglomeração.

Assume-se então, que cada indivíduo k possui dois atributos:

1. classificação não-dominada: $rank_k$
2. distância de aglomeração: $crowd_k$

Uma nova ordem parcial é definida. $p \preceq^* q$, ou seja, a solução representada pelo indivíduo p é melhor que a solução representada pelo indivíduo q se:

$$(rank_p < rank_q) \vee \left((rank_p = rank_q) \wedge (crowd_p > crowd_q) \right) \quad (4.11)$$

Isto é, entre duas soluções de diferentes fronteiras, prefere-se a solução com menor $rank$. Se duas soluções pertencem à mesma fronteira, a preferência é dada à solução que pertença à região menos povoada, ou seja, com maior $crowd$.

Esta nova ordem parcial, permite que a distância de aglomeração seja utilizada juntamente com o método de classificação da população (que também considera implicitamente a informação sobre factibilidade da solução) durante o processo de seleção dos indivíduos da população auxiliar R_g para compor a população da próxima geração (P_{g+1}). O esquema geral deste processo é apresentado na Figura 4.4 (Deb 2011):




Figura 4.4: Esquema do processo seletivo para formação da população da geração $g+1$: hidroNSGA e hidroNSDE.

Se F_1 é menor que o tamanho da população (TP), todos os membros de F_1 são escolhidos para a nova população (geração $g + 1$). Os membros restantes são escolhidos das fronteiras subsequentes. Suponha-se que F_l é a última fronteira antes que a nova população atinja o tamanho TP , mas não todos os membros de F_l podem ser acomodados. Para escolher os membros de R_g que completem a nova população, o operador $\preceq^*$ é utilizado.

O pseudocódigo da implementação do operador $\preceq^*$, juntamente com a obtenção dos atributos $rank_k$ e $crowd_k$ para todos os indivíduos da população auxiliar R_g , são apresentados a seguir. Para isso, deve-se considerar:

1. S_p : conjunto de soluções que a solução p domina.
2. n_p : número de soluções que dominam a solução p .

Primeiramente, a primeira fronteira deve ser obtida. Uma preparação para a obtenção das demais fronteiras também é realizada.

```

 $R_g = P_g \cup Q_g$ ;
 $F_1 = \emptyset$ ;    // primeira fronteira ainda sem elementos
para cada  $p \in R_g$ 
{
     $S_p = \emptyset$ ;
     $n_p = 0$ ;
    para cada  $q \in R_g$  e  $q \neq p$ 
    {
        se (  $p \preceq q$  )    //  $p$  domina  $q$ 
        {
             $S_p = S_p \cup \{q\}$ ;
        }
        senão se (  $q \preceq p$  )    //  $q$  domina  $p$ 
        {
             $n_p = n_p + 1$ ;
        }
    }
    se (  $n_p = 0$  )    // nenhuma solução domina  $p$ , logo  $p$  pertence a  $F_1$ 
    {
         $F_1 = F_1 \cup \{p\}$ ;
         $rank_p = 1$ ;
    }
}

```

A primeira fronteira está formada. Quando o procedimento de ordenação encontrar um número suficiente de fronteiras para completar TP indivíduos, não é necessário que a ordenação continue, garantindo assim um algoritmo mais eficiente. Seja P_{g+1} a nova população, que passará para a geração $g + 1$:

```

 $P_{g+1} = \emptyset;$     // nova população ainda sem elementos
 $l = 1;$     // contador de fronteiras
// enquanto a fronteira  $l$  couber totalmente na nova população
enquanto (  $|P_{g+1}| + |F_l| \leq TP$  )
{
     $P_{g+1} = P_{g+1} \cup F_l;$     // copia os elementos da fronteira  $l$  na nova população
     $Z = \emptyset;$     // armazenará os membros da próxima fronteira
    para cada  $p \in F_l$ 
    {
        para cada  $q \in S_p$ 
        {
             $n_q = n_q - 1;$ 
            se (  $n_q = 0$  )
            {
                 $rank_q = l + 1;$ 
                 $Z = Z \cup \{q\};$ 
            }
        }
    }
     $l = l + 1;$     // próxima fronteira foi encontrada, atualiza contador
     $F_l = Z;$  // os membros da nova fronteira podem ser colocados em  $\hat{P}_{g+1}$  ?
}

```

Se o critério de parada foi atingido, ou seja, os elementos da fronteira F_l não podem ser copiados para a nova população P_{g+1} , mas esta população ainda não atingiu o tamanho TP , segundo o operador $\preceq^*$, é a distância de aglomeração *crowding distance* que decidirá quais membros de F_l serão acomodados em P_{g+1} .

O pseudocódigo a seguir apresenta o tratamento desta situação, onde $crowd_{k,F_l}$ representa a distância de aglomeração da solução k pertencente à fronteira F_l ; f_{k,F_l}^j representa o valor da j -ésima função-objetivo para a solução k pertencente à fronteira F_l e F_l^k representa a k -ésima solução da fronteira F_l .

Uma solução com o menor valor de aglomeração pertence a uma região mais cheia, ou seja, uma região já representada por várias outras soluções.

```

se (  $|P_{g+1}| < TP$  )
{
    // calcula crowd das soluções pertencentes à fronteira  $F_l$ 
     $tl = |F_l|$ ; // número de elementos da fronteira  $F_l$ 
    para cada  $k \in F_l$ 
    {
         $crowd_k = 0$ ; // inicialização
    }
    para cada objetivo  $j \in \{1, \dots, m\}$ 
    {
        ordenaC(  $F_l, j$  ); // ordena  $F_l$  de acordo com o objetivo  $j$ , em ordem crescente
        // soluções das extremidades recebem crowd infinito
         $crowd_{1, F_l} = \infty$ ; // primeira solução de  $F_l$  após a ordenação
         $crowd_{tl, F_l} = \infty$ ; // última solução de  $F_l$  após a ordenação
        para cada  $k \in \{2, \dots, tl - 1\}$  // para as demais soluções da fronteira
        {
             $crowd_{k, F_l} = crowd_{k, F_l} + (f_{k+1, F_l}^j - f_{k-1, F_l}^j)$ ;
        }
    }
    ordenaD(  $F_l, crowd$  ); // ordena  $F_l$  de acordo com o crowd, em ordem decrescente
     $k = 1$ ; // início na primeira solução de  $F_l$  após a ordenação
    enquanto (  $|P_{g+1}| < TP$  ) // enquanto não completar a nova população
    {
         $P_{g+1} = P_{g+1} \cup \{F_l^k\}$ ; // adiciona a  $k$ -ésima solução de  $F_l$ 
         $k = k + 1$ ;
    }
}

```

Os operadores de seleção, mutação e cruzamento, específicos de cada algoritmo multiobjetivo, serão apresentados nas seções a seguir.

4.2.1 Formulação Multiobjetivo e Algoritmo Genético: hidroNSGA

Os operadores de cruzamento e mutação, para o caso multiobjetivo, são os mesmos da formulação monobjetivo, apresentados na Seção 4.1.1 para o hidroGA. Apenas o operador de seleção foi alterado para abordar conceitos de dominância e aglomeração das soluções.

Todos os indivíduos que representam soluções factíveis podem ser selecionados e novamente, o processo de seleção utilizado é o torneio. O operador $\preceq^*$, definido na Seção anterior é utilizado para a composição da população de pais.

Duas soluções factíveis, p e q são selecionadas aleatoriamente da população P_g para competirem. Se $p \preceq^* q$, p fará parte da população de pais; caso contrário, q será escolhida. O processo se repete até que a população de pais se complete com TP indivíduos. Pares de pais são formados, aleatoriamente, com os indivíduos desta seleção que passaram pelo torneio, podendo passar pelo cruzamento e pela mutação, dependendo da probabilidade, PC e PM associadas aos operadores. Os operadores são executados da mesma forma que o proposto para o hidroGA:

dois pais para a formação de dois filhos. Desta forma, a população de filhos Q_g também será composta por TP indivíduos.

4.2.2 Formulação Multiobjetivo e Evolução Diferencial: hidroNSDE

No caso multiobjetivo, com o intuito de deixar o algoritmo hidroNSDE com as mesmas características que o hidroNSGA, também adotou-se uma população Q_g de tamanho TP , formada pelos indivíduos que passaram pelos operadores de mutação e cruzamento (equivalente à população de filhos).

Cada solução *trial* $q_k''(i, t)$, que irá compor a população Q_g está associada à uma solução *donor* $q_k'(i, t)$ que, por sua vez, associa-se a uma solução *target* $q_k(i, t)$. Logo, para compor Q_g , são selecionadas TP soluções *target*. Se todas as soluções da população original P_g forem factíveis, cada uma será *target* (ou seja, base dos operadores de mutação e crossover) apenas uma vez. Caso contrário, cada solução factível poderá ser *target* mais de uma vez, com a garantia de que todas sejam selecionadas.

O operador de mutação foi novamente dividido em dois casos: um para tratar as soluções pertencentes à fronteira F_1 e outro para tratar as demais soluções factíveis. A idéia destes novos operadores ao invés dos operadores clássicos de mutação da Evolução Diferencial surgiu durante os experimentos computacionais, quando observou-se uma convergência muito lenta do hidroNSDE em relação ao hidroNSGA, por falta de uma pressão seletiva durante as fases de mutação e cruzamento. O hidroNSGA tem a seleção por torneio a seu favor, que de certa forma, privilegia os melhores indivíduos para mutação e cruzamento. Os novos operadores de mutação propostos para o hidroNSDE aceleraram a aproximação da Fronteira de Pareto.

Se a solução *target* $q_k(i, t)$ pertence à fronteira F_1 , ou seja, já é uma solução de qualidade, aplica-se mutação como busca local, com o intuito de melhorar a solução, mas sem sair da região promissora. Logo, a solução *donor* é definida como:

$$q_k'(i, t) = q_k(i, t) + F d \quad (4.12)$$

onde F é a constante de mutação que pode ser interpretada como o passo a ser dado na direção d . A direção de mutação d , aleatória e pertencente ao intervalo $[-\frac{5q_k(i, t)}{100}, \frac{5q_k(i, t)}{100}]$, aumenta ou diminui a vazão turbinada em até 5% de seu valor atual.

Para as soluções *target* pertencentes às fronteiras F_i , com $i > 1$, a seguinte mutação é realizada:

$$q_k'(i, t) = q_k(i, t) + F(q_{F_1}(i, t) - q_k(i, t)) + F(q_{r_1}(i, t) - q_{r_2}(i, t)) \quad (4.13)$$

Desta forma, a mutação carrega informações sobre a solução atual $q_k(i, t)$, sobre uma solução $q_{F_1}(i, t)$ aleatoriamente escolhida entre os indivíduos da primeira fronteira F_1 , além de uma variação aleatória $q_{r_1}(i, t) - q_{r_2}(i, t)$. Sendo que, com $k \neq r_1 \neq r_2$ as soluções r_1 e r_2 devem pertencer a fronteiras melhores que a solução k , ou seja, $rank_k > rank_{r_1}$ e $rank_k > rank_{r_2}$. O intuito é fazer com que as direções se restrinjam a regiões promissoras. Com isso, espera-se que os indivíduos aproximem-se mais da fronteira de Pareto.

Após o cruzamento, realizado entre as soluções *target* $q_k(i, t)$ e *donor* $q'_k(i, t)$, a população Q_g é formada. O operador de cruzamento é o mesmo proposto para a formulação monobjetivo (Seção 4.1.2).

Na maioria dos algoritmos de Evolução Diferencial, a seleção gulosa é utilizada (Seção 4.1.2). Para a formulação multiobjetivo, adotou-se a comparação global. A nova população P_{g+1} é obtida com a ordenação da população auxiliar R_g , formada pela população atual P_g e pela população de soluções *trial* Q_g , através do operador $\preceq^*$ (como implementado para o hidroNSGA).

Estudos de Caso

Neste capítulo serão apresentados os resultados obtidos pelos quatro algoritmos implementados: hidroGA, hidroDE, hidroNSGA e hidroNSDE. Na análise dos resultados, são realizadas comparações entre o Algoritmo Genético e a abordagem de Evolução Diferencial. Comparações qualitativas e quantitativas com o modelo HydroMax (Cicogna & Soares 2005, Cicogna 1999, Cicogna 2003) foram realizadas com o objetivo de validar os métodos propostos e discutir as características das soluções obtidas. Os resultados do HydroMax constam no Apêndice A, para conhecimento.

Os testes foram realizados com Subsistemas Brasileiros, por possuírem características específicas que os diferenciam dos demais sistemas no mundo (Cicogna & Soares 2003). Para as análises dos resultados foram escolhidos conjuntos de usinas da região Sudeste do Brasil. O horizonte de planejamento dos estudos iniciais, 12 meses, foi escolhido em virtude da sazonalidade apresentada nas bacias escolhidas para o estudo, típicas da região Sudeste. Além disso, os estudos de otimização de sistemas hidrelétricos em ambientes determinísticos com horizontes maiores (até 5 anos) revelaram a repetição do comportamento dos sistemas quanto à trajetória de volume armazenado. Ou seja, mesmo em estudos com horizontes maiores que um ano, o comportamento ótimo dos sistemas hidrelétricos faz uso predominante da regularização intra-anual (Francato 1997). Para a verificação desta característica, estudos com 48 meses também são apresentados (Seção 5.1.2).

Foi assumida a hipótese determinística para as vazões naturais afluentes a cada reservatório, considerando a vazão mensal de cada usina igual à média de longo termo (MLT). A consideração de um modelo determinístico que lida com séries históricas ou sintéticas é útil para estudos sobre planejamento da operação de sistemas hidrelétricos (Rosenthal 1981).

Os dados foram obtidos a partir do histórico de vazões (de 1931 a 2007) disponibilizado

pelo Operador Nacional do Sistema Elétrico (ONS)¹. A partir do histórico, percebe-se que os reservatórios das usinas atingem seus valores máximos, na maior parte dos anos, sempre no mês de maio. É em maio, com os reservatórios cheios, que se iniciam as execuções do algoritmo. Considerando a função-objetivo penalizada, os reservatórios tendem a voltar ao nível máximo no último período de tempo, ao mesmo tempo que o algoritmo tenta minimizar a complementação térmica. A taxa de juros adotada foi de 12% ao ano, a mesma que é estabelecida para uso pelo ONS (ANEEL 2004). Os demais dados de todas as usinas foram retirados do banco de dados HydroData (Cicogna & Soares 2003).

Os testes foram realizados em uma plataforma Linux, processador Intel Core i7 2.93 GHz e 8 Gb de memória RAM. A linguagem de programação utilizada foi C.

Na próxima seção são apresentados os resultados com a formulação monobjetivo. Na Seção 5.2 são apresentados os resultados com a formulação multiobjetivo.

5.1 Formulação Monobjetivo: hidroGA e hidroDE

Os testes desta seção consideram a minimização do custo da complementação térmica penalizada, conforme especificado na Seção 4.1 do capítulo anterior. Para isso, as seguintes funções-objetivo podem ser utilizadas:

Combinação das equações 1.16 e 1.19, da Seção 1.3:

$$\text{Minimizar} \quad \sum_{t=1}^T \left[\lambda(t) \cdot \mathcal{C}(G(t)) \right] - \sum_{i=1}^N \mathcal{M}(i) \cdot x(i, T) \quad (5.1)$$

Combinação das equações 1.16 e 1.20, da Seção 1.3:

$$\text{Minimizar} \quad \sum_{t=1}^T \left[\lambda(t) \cdot \mathcal{C}(G(t)) \right] + \sum_{i=1}^N \mathcal{M}(i) \cdot \left(s(i, T) - x(i, T) \right)^2 \quad (5.2)$$

Nos dois casos, o vetor de constantes positivas de penalização $\mathcal{M}(\cdot)$ é obtido empiricamente, de maneira que os reservatórios de todas as usinas consigam recuperar seus volumes.

Os testes foram divididos da seguinte maneira:

- Caso 1: Operação em Cascata: Furnas e Água Vermelha.
- Caso 2: Horizonte de Planejamento de 48 meses.
- Caso 3: Usina a Fio d'água.

¹http://www.ons.org.br/operacao/vazoes_naturais.aspx

- Caso 4: 14 Usinas.

Em todos os casos de estudo foram realizadas várias rodadas de testes. Com o objetivo de analisar apenas as melhores soluções, na formulação monobjetivo, todos os resultados apresentados serão referentes ao melhor indivíduo da população, em cada rodada. A seguir, a descrição e análise de cada um dos casos de estudo.

5.1.1 Caso 1: Operação em Cascata: Furnas e Água Vermelha

Para este estudo foram escolhidas duas usinas com reservatório interligados, Furnas e Água Vermelha, um horizonte de planejamento de 12 meses e demanda de 2000 MW mensais. Os parâmetros comuns ao hidroGA e ao hidroDE são: tamanho da população $TP = 100$ indivíduos e vetor de penalidade $\mathcal{M}(\cdot) = [200, 120]$. A Equação 5.1 foi utilizada como função-objetivo para este caso.

Os primeiros testes foram realizados com o intuito de testar a sensibilidade da solução em relação às alterações nos valores dos parâmetros: número de gerações G , taxas de cruzamento e taxas de mutação, respectivamente, PC , PM (hidroGA) e CR , F (hidroDE). Para cada algoritmo foram realizadas 180 rodadas de teste, ou seja, 10 rodadas para cada uma das 18 combinações de parâmetros consideradas. As Tabelas 5.1, 5.2 e 5.3 apresentam os resultados de geração hidrelétrica obtidos com o melhor indivíduo da população na última geração. Em cada célula, o primeiro valor é referente à média da geração média mensal, o segundo apresenta a média do desvio padrão da geração mensal e o terceiro refere-se à média da geração hidrelétrica total (considerando todo o horizonte de planejamento). Estes três valores foram calculados considerando, em cada caso, as 10 rodadas executadas.

Estes dados correspondem às melhores soluções, ou seja, para cada combinação de parâmetros em cada rodada de testes, a solução que apresentou o menor custo penalizado dentre todas as soluções da população foi escolhida para análise.

Como critério de decisão para a escolha da melhor combinação de parâmetros, adotou-se o menor desvio médio da geração hidrelétrica. Com esta consideração espera-se obter soluções com geração hidrelétrica mais estável ou aproximadamente constante. Verificando os menores valores de desvio² nas Tabelas 5.1, 5.2 e 5.3³, conclui-se que, para este caso de estudo e seguindo este critério, a alternativa $G = 150$, $PM = 0,1$ e $PC = 0,9$ representa a melhor configuração de parâmetros para o hidroGA. Para o hidroDE, a melhor configuração de parâmetros é representada pela alternativa $G = 150$, $F = 0,5$ e $CR = 0,9$. Além disso, para estas combinações

²Segundo valor de cada célula.

³As combinações com os menores valores de desvio estão em destaque nas tabelas.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	1.824,29 31,91 21.891,48	1.827,75 63,58 21.933,04
0,1	0,6	1.824,06 15,55 21.888,76	1.825,21 28,78 21.902,51
0,1	0,9	1.824,18 14,22 21.890,12	1.825,75 41,15 21.909,01
0,3	0,6	1.824,52 23,39 21.894,20	1.824,11 10,70 21.889,31
0,3	0,9	1.824,46 16,61 21.893,49	1.824,06 17,96 21.888,71
0,5	0,9	1.824,81 21,97 21.897,76	1.823,85 7,26 21.886,19

Tabela 5.1: Geração Hidrelétrica ($\overline{MW}$), $G = 50$ gerações, Média, Desvio e Total – Caso 1.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	1.823,98 14,56 21.887,76	1.824,67 23,80 21.896,02
0,1	0,6	1.823,83 10,19 21.885,95	1.823,94 8,56 21.887,25
0,1	0,9	1.823,85 9,12 21.886,21	1.824,43 33,22 21.893,12
0,3	0,6	1.824,08 11,26 21.888,96	1.823,75 3,93 21.885,06
0,3	0,9	1.824,00 10,05 21.888,05	1.823,93 11,04 21.887,18
0,5	0,9	1.824,23 15,44 21.890,75	1.823,76 3,27 21.885,10

Tabela 5.2: Geração Hidrelétrica ($\overline{MW}$), $G = 100$ gerações, Média, Desvio e Total – Caso 1.

de parâmetros, o hidroDE tem menor desvio médio (3,03) que o hidroGA (7,27), apresentando soluções com geração hidrelétrica mensal mais estável.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	1.823,82 9,75 21.885,79	1.824,06 14,39 21.888,72
0,1	0,6	1.823,81 7,91 21.885,71	1.823,87 6,95 21.886,39
0,1	0,9	1.823,85 7,27 21.886,22	1.824,24 17,41 21.890,87
0,3	0,6	1.823,76 8,50 21.885,10	1.823,76 3,54 21.885,06
0,3	0,9	1.823,95 8,13 21.887,38	1.823,77 6,91 21.885,26
0,5	0,9	1.824,15 11,25 21.889,84	1.823,76 3,03 21.885,07

Tabela 5.3: Geração Hidrelétrica ($\overline{MW}$), $G = 150$ gerações, Média, Desvio e Total – Caso 1.

Os tempos médios de execução, em segundos, de cada conjunto de rodadas, estão apresentados na Tabela 5.4. Em cada célula, os valores correspondem, respectivamente a, $G = 50$ gerações, $G = 100$ gerações e $G = 150$ gerações.

Os gráficos a seguir apresentam o *fitness* do melhor indivíduo e a média do *fitness* da população juntamente com seu desvio padrão, durante as $G = 150$ gerações, obtidos com o hidroGA e com o hidroDE. Para esta análise, foram consideradas as melhores configurações de parâmetros apontadas anteriormente: $PM = 0,1$ e $PC = 0,9$ para o hidroGA (Figura 5.1), $F = 0,5$ e $CR = 0,9$ para o hidroDE (Figura 5.2). Cada gráfico apresenta os resultados de 10 rodadas de testes.

O hidroGA consegue manter a população mais diversificada durante todo o processo evolutivo, o que é percebido através da média e do desvio do *fitness* dos indivíduos da população (Figura 5.1). Com o hidroDE, o *fitness* da população converge mais rapidamente, tendendo ao *fitness* do melhor indivíduo. A partir da 50ª geração, a diversidade da população aumenta (Figura 5.2), pois o Operador de Manutenção de Diversidade (Seção 4.1) inseriu novos indivíduos na população. Em relação à convergência do *fitness* do melhor indivíduo, hidroGA e hidroDE obtiveram soluções com as mesmas características.

Outras análises com a melhor solução obtida com o hidroGA ($PM = 0,1$ e $PC = 0,9$) e com

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	0,165	0,161
		0,331	0,323
		0,497	0,479
0,1	0,6	0,169	0,163
		0,337	0,326
		0,500	0,485
0,1	0,9	0,171	0,163
		0,342	0,316
		0,506	0,472
0,3	0,6	0,176	0,167
		0,350	0,325
		0,526	0,484
0,3	0,9	0,177	0,161
		0,353	0,315
		0,531	0,471
0,5	0,9	0,185	0,162
		0,364	0,316
		0,552	0,460

Tabela 5.4: Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 50$, $G = 100$ e $G = 150$ – Caso 1.




Figura 5.1: Evolução do *fitness* do melhor indivíduo do hidroGA, em 10 rodadas de testes – Caso 1.




Figura 5.2: Evolução do *fitness* do melhor indivíduo do hidroDE, em 10 rodadas de testes – Caso 1.

o hidroDE ($F = 0,5$ e $CR = 0,9$) estão apresentadas a seguir⁴. Os gráficos referem-se ao caso com $G = 150$. Com menos gerações é possível obter resultados quantitativamente semelhantes, em relação a geração hidrelétrica total, como foi verificado anteriormente (Tabelas 5.1, 5.2 e 5.3).

⁴As informações a seguir são referentes a uma das dez rodadas executadas. As demais rodadas, para a mesma configuração de parâmetros obtiveram as mesmas características e para melhor visualização dos resultados, foram suprimidas.

Porém, com mais gerações, as soluções melhoram qualitativamente. Empiricamente, observou-se que a geração total $H(t)$ tem maiores variações com menos gerações e um comportamento aproximadamente constante com mais gerações.

Os volumes dos reservatórios obtidos nestes casos de estudo estão apresentados nas Figuras 5.3 e 5.4. O reservatório de Furnas sofreu deplecionamento e o de Água Vermelha manteve-se cheio durante todo o período de tempo, uma característica de soluções que maximizam a produtividade em cascata (Cicogna 2003, Cicogna & Soares 2005): a usina a montante (Furnas) regulariza a vazão afluente da usina a jusante (Água Vermelha). A função-objetivo penalizada conseguiu fazer com que o volume do reservatório de Furnas retornasse ao nível máximo. Os dois métodos de resolução obtiveram soluções com características semelhantes.




Figura 5.3: Volumes dos Reservatórios, hidroGA – Caso 1.




Figura 5.4: Volumes dos Reservatórios, hidroDE – Caso 1.

Na usina de Furnas, os primeiros meses correspondem ao período de seca (maio a novembro) e a vazão turbinada é maior que a vazão afluente (Figura 5.5). Com isso o reservatório é

deplecionado (Figuras 5.3 e 5.4). De dezembro a abril (período de cheia), a vazão turbinada fica abaixo da vazão afluenta. Isto faz com que o reservatório recupere o armazenamento até atingir o máximo novamente, no último período de tempo.

A usina de Água Vermelha manteve seu reservatório cheio (Figuras 5.3 e 5.4) durante todo o tempo. No período de cheia a vazão turbinada aumenta (Figura 5.6), mas não ocorre vertimento⁵ porque a defluência de Furnas (a montante) é controlada pela otimização, regularizando a afluência de Água Vermelha.




Figura 5.5: Vazões de Furnas – Caso 1.




Figura 5.6: Vazões de Água Vermelha – Caso 1.

⁵No caso 1, em nenhuma das usinas ocorre vertimento.

As gerações hidrelétricas obtidas por cada algoritmo estão apresentadas na Figura 5.7.




Figura 5.7: Geração Hidrelétrica mensal – Caso 1.

5.1.2 Caso 2: Horizonte de Planejamento de 48 meses

Para este estudo, foram mantidas as usinas de Furnas e Água Vermelha e escolhido um horizonte de planejamento maior: 48 meses. A demanda foi fixada em 2000 MW mensais e os parâmetros comuns ao hidroGA e ao hidroDE são: tamanho da população $TP = 100$ indivíduos, e vetor de penalidade $\mathcal{M}(\cdot) = [200, 120]$. A Equação 5.1 foi utilizada como função-objetivo para este caso.

O número de gerações foi fixado em $G = 600$, com o objetivo de se obter uma geração hidrelétrica total mais uniforme. Para verificar a variação da solução em relação às alterações nos valores das taxas de cruzamento e mutação, foram realizadas, para cada algoritmo, 60 rodadas de teste, ou seja, 10 rodadas para cada uma das 6 combinações de parâmetros consideradas. A Tabela 5.5 apresenta os resultados de geração hidrelétrica obtidos com o melhor indivíduo da população, na última geração. Em cada célula, o primeiro valor é referente à média da geração mensal, o segundo apresenta a média do desvio padrão da geração mensal e o terceiro refere-se à média da geração hidrelétrica total.

Novamente, o desvio da geração hidrelétrica será considerado como critério de decisão para a escolha da melhor combinação de parâmetros. Verificando os menores valores de desvio, conclui-se que, para este caso de estudo, as alternativas que representam as melhores configurações de parâmetros são $PM = 0,1$ e $PC = 0,9$ para o hidroGA, $F = 0,5$ e $CR = 0,9$ para o hidroDE.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	1.823,62 20,79 87.533,89	1.824,34 33,49 87.568,55
0,1	0,6	1.823,66 17,99 87.535,53	1.824,32 48,28 87.567,44
0,1	0,9	1.823,71 16,62 87.537,91	1.823,83 88,91 87.543,98
0,3	0,6	1.823,61 28,95 87.533,25	1.823,86 43,77 87.545,40
0,3	0,9	1.823,76 28,64 87.540,55	1.823,40 77,47 87.523,20
0,5	0,9	1.823,99 35,65 87.551,45	1.823,73 8,98 87.539,18

Tabela 5.5: Geração Hidrelétrica ($\overline{MW}$), $G = 600$ gerações, Média, Desvio e Total – Caso 2.

Como no primeiro estudo (Seção 5.1.1), para estas combinações, o hidroDE obteve o menor desvio médio (10,69, contra 18,96 do hidroGA), apresentando uma geração hidrelétrica mensal mais estável.

Os tempos médios de execução, em segundos, de cada conjunto de rodadas, estão apresentados na Tabela 5.6.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	8,795	7,811
0,1	0,6	9,321	7,754
0,1	0,9	9,655	7,314
0,3	0,6	10,429	7,770
0,3	0,9	10,678	7,385
0,5	0,9	11,485	7,429

Tabela 5.6: Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 600$ – Caso 2.

As características das soluções são semelhantes ao primeiro caso de estudo. Neste caso, novamente, não ocorre vertimento. As Figuras 5.8 e 5.9 apresentam os volumes do reservatórios de Furnas e Água Vermelha. Os algoritmos conseguiram recuperar o volume do reservatório de Furnas, chegando sempre ao máximo no mês de maio de cada ano.

A Figura 5.10 apresenta os resultados de geração hidrelétrica total e por usina, obtidos com




Figura 5.8: Volumes dos reservatórios, hidroGA – Caso 2.




Figura 5.9: Volumes dos reservatórios, hidroDE – Caso 2.

os dois algoritmos. O hidroDE conseguiu uma geração total mais uniforme que o hidroGA, com o mesmo número de gerações.

5.1.3 Caso 3: Usina a Fio d'água

Este estudo tem o objetivo de verificar o comportamento do algoritmo proposto com usinas a fio d'água (sem reservatórios de capacidade regularizadora). Foram consideradas as usinas de Furnas, Estreito (fio d'água) e Água Vermelha, em um horizonte de planejamento de 12 meses. A demanda foi fixada em 2700 MW mensais e os parâmetros comuns ao hidroGA e ao hidroDE são: tamanho da população $TP = 100$ indivíduos, gerações $G = 100$ e vetor de penalidade $\mathcal{M}(\cdot) = [350, 0, 120]$. A Equação 5.1 foi utilizada como função-objetivo para este caso.

Foram realizadas, para cada algoritmo, 60 rodadas de teste, ou seja, 10 rodadas para cada uma das 6 combinações de parâmetros consideradas. A Tabela 5.7 apresenta os resultados de geração hidrelétrica obtidos. Em cada célula, o primeiro valor é referente à média da geração média mensal, o segundo apresenta a média do desvio padrão da geração mensal e o terceiro refere-se à média da geração hidrelétrica total.




Figura 5.10: Geração Hidrelétrica mensal – Caso 2.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	2.430,64	2.432,26
		5,06	10,46
		29.167,67	29.187,11
0,1	0,6	2.430,13	2.430,13
		4,40	4,27
		29.161,58	29.161,60
0,1	0,9	2.430,56	2.433,99
		3,75	13,16
		29.166,69	29.207,85
0,3	0,6	2.429,57	2.430,16
		7,22	3,36
		29.154,81	29.161,94
0,3	0,9	2.429,86	2.430,74
		6,51	3,93
		29.158,28	29.168,82
0,5	0,9	2.431,33	2.430,06
		11,57	2,99
		29.175,96	29.160,69

Tabela 5.7: Geração Hidrelétrica ($\overline{MW}$), $G = 100$ gerações, Média, Desvio e Total – Caso 3.

Verificando os menores valores de desvio, novamente, as melhores configurações de parâmetros são $PM = 0,1$ e $PC = 0,9$ (hidroGA), $F = 0,5$ e $CR = 0,9$ (hidroDE). Como nos

estudos anteriores (Seções 5.1.1 e 5.1.2), para estas combinações, o hidroDE obteve o menor desvio médio (2,99, contra 3,75 do hidroGA).

Os tempos médios de execução, em segundos, de cada conjunto de rodadas, estão apresentados na Tabela 5.8.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	0,495	0,477
0,1	0,6	0,509	0,488
0,1	0,9	0,524	0,462
0,3	0,6	0,540	0,490
0,3	0,9	0,550	0,465
0,5	0,9	0,573	0,466

Tabela 5.8: Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 100$ – Caso 3.

Os resultados obtidos para as usinas de Furnas e Água Vermelha, foram semelhantes ao primeiro estudo (Seção 5.1.1). Neste caso, novamente, a regularização feita por Furnas foi suficiente para eliminar os vertimentos das usinas de Furnas e Água Vermelha. A Figura 5.11 apresenta o volume útil e a vazão turbinada da usina de Furnas. Vale lembrar que, Estreito, localizada entre as usinas de Furnas e Água Vermelha, é usina fio d'água, logo, não possui volume útil. Usinas a fio d'água não possuem grande influência na solução ótima, quando a vazão incremental que atua entre uma usina com reservatório (Furnas) e outra fio d'água (Estreito) é pequena (Cicogna & Soares 2005). Nota-se pequenas modificações nas trajetórias de vazão turbinada de Furnas (Figura 5.11) para compensar a não horizontalidade da geração em Estreito, de forma que a soma total seja horizontal.




Figura 5.11: Volume útil (em %) e Vazão Turbinada (em m^3/s) de Furnas – Caso 1 e Caso 3.

A Figura 5.12 apresenta os resultados de geração hidrelétrica total e por usina, obtidos com cada algoritmo.




Figura 5.12: Geração Hidrelétrica mensal – Caso 3.

Nos casos em que a vazão incremental que atua entre uma usina com reservatório e outra a fio d'água é grande, a regularização exigida da usina com reservatório pode ser afetada pela usina a fio d'água, já que esta não possui capacidade de regularização da vazão afluente. Se fosse esta a situação deste caso de estudo, a tendência de Água Vermelha operar como usina a fio d'água poderia ser alterada se sua vazão incremental fosse muito alta; Água Vermelha passaria a deplecionar seu reservatório.

5.1.4 Caso 4: 14 usinas

São analisados neste estudo, os resultados obtidos pelos algoritmos propostos para um sistema composto por 14 usinas hidrelétricas, abrangendo parte do Sistema Sudeste Brasileiro e considerando usinas com reservatório e a fio d'água. O objetivo é verificar o comportamento dos algoritmos propostos, quanto ao crescimento do número de usinas. Foram consideradas 8 usinas com reservatório (Emborcação, Itumbiara, São Simão, Furnas, Peixoto, Marimbondo, Água Vermelha e Ilha Solteira) e 6 usinas a fio d'água (Cachoeira Dourada, Estreito, Jaguará, Igarapava, Volta Grande e Porto Colômbia), em um horizonte de planejamento de 12 meses. A

demanda foi fixada em 11500 MW mensais e os parâmetros comuns ao hidroGA e o hidroDE são: tamanho da população $TP = 100$ indivíduos, $G = 1000$ gerações e vetor de penalidade $\mathcal{M}(\cdot) = [1900, 1700, 0, 1200, 2500, 2500, 0, 0, 0, 0, 0, 1200, 1100, 2100]$. A Equação 5.1 foi novamente utilizada como função-objetivo.

Foram realizadas 10 rodadas de testes, para cada algoritmo e para cada uma das 6 combinações de parâmetros consideradas. A Tabela 5.9 apresenta os resultados de geração hidrelétrica obtidos: média da geração média mensal, média do desvio padrão da geração mensal e média da geração hidrelétrica total.

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	10.750,42 159,39 129.004,99	10.916,68 215,63 131.000,16
0,1	0,6	10.770,76 171,80 129.249,13	10.930,54 280,70 131.166,46
0,1	0,9	10.792,20 140,93 129.506,38	10.912,67 273,92 130.952,03
0,3	0,6	10.767,57 188,82 129.210,80	10.836,69 202,46 130.040,24
0,3	0,9	10.773,54 189,04 129.282,49	10.834,50 191,33 130.014,04
0,5	0,9	10.791,71 200,18 129.500,52	10.733,94 103,30 128.807,28

Tabela 5.9: Geração Hidrelétrica ($\overline{MW}$), $G = 1000$ gerações, Média, Desvio e Total – Caso 4.

Verificando os menores valores de desvio, novamente, as melhores configurações de parâmetros são $PM = 0,1$ e $PC = 0,9$ (hidroGA), $F = 0,5$ e $CR = 0,9$ (hidroDE). Como nos estudos anteriores, o hidroDE apresentou desvio médio menor que o hidroGA (140,93 e 103,30, respectivamente). Apesar de apresentar desvio médio maior, o hidroGA conseguiu obter gerações média e total maiores que o hidroDE.

Os tempos médios de execução, em segundos, de cada conjunto de rodadas, estão apresentados na Tabela 5.10.

As trajetórias de volume das usinas com reservatório estão apresentadas na Figura 5.13. Foram incluídas também, as trajetórias de volume obtidas com o modelo HydroMax (Cicogna & Soares 2005, Cicogna 1999, Cicogna 2003).

PM ou F	PC ou CR	hidroGA	hidroDE
0,1	0,2	73,089	28,847
0,1	0,6	76,506	25,811
0,1	0,9	81,015	23,740
0,3	0,6	105,108	26,292
0,3	0,9	104,054	23,926
0,5	0,9	120,732	24,821

Tabela 5.10: Médias dos tempos de execução (s) de cada conjunto de rodadas, $G = 1000$ – Caso 4.

A usina de Furnas apresentou comportamento semelhante ao primeiro estudo (Seção 5.1.1). Ilha Solteira, usina a jusante das cascatas, manteve seu reservatório cheio durante todo o horizonte de planejamento, em ambas as soluções apresentadas (hidroGA e hidroDE), e teve a vazão afluyente (Figura 5.14) regularizada pelas usinas a montante.

A Figura 5.15 apresenta os resultados de geração hidrelétrica total, obtidos com os dois algoritmos, com os parâmetros $PM = 0,1$ e $PC = 0,9$ (hidroGA), $F = 0,5$ e $CR = 0,9$ (hidroDE).

Neste caso, tanto a solução apresentada pelo hidroGA, quanto a solução apresentada pelo hidroDE apresentaram vertimentos nas usinas de São Simão e Jaguará. Em São Simão, os vertimentos ocorreram no período 12 do planejamento. Em Jaguará, os vertimentos ocorreram nos períodos 2, 3, 4, 5, 6, 7 e 9 (hidroGA) e 1, 2, 3, 4, 5, 6 e 7 (hidroDE).

Os resultados apresentados nos quatro casos de estudo referem-se ao melhor indivíduo de cada população. Mas outras soluções de qualidade também estão disponíveis.

Variando o parâmetro de penalização $\mathcal{M}(\cdot)$ é possível alternar a importância dos objetivos. Mas o ajuste deste parâmetro pode se tornar uma dificuldade com o aumento do número de usinas. Na próxima seção, a Otimização Multiobjetivo será aplicada de forma explícita ao problema, sem a necessidade de nenhum parâmetro adicional de penalização ou ponderação entre os objetivos. O conjunto de soluções é obtido em uma única execução do algoritmo.

5.2 Formulação Multiobjetivo: hidroNSGA e hidroNSDE

Os testes desta seção abordam o problema em sua forma multiobjetivo, com a aplicação dos dois algoritmos propostos para esta formulação: hidroNSGA e hidroNSDE. Quando se mede o desempenho de um algoritmo de resolução de problemas de Otimização Multiobjetivo, três aspectos relevantes devem ser levados em consideração (Cortés 2004):




Figura 5.13: Volumes dos Reservatórios – Caso 4.

- Aproximação da verdadeira Fronteira de Pareto;
- Dispersão uniforme das soluções;
- Maximização da quantidade de elementos não-dominados.

Para medir o desempenho dos algoritmos propostos em relação à dispersão das soluções na fronteira não-dominada, será utilizada a métrica proposta por Schott (1995).




Figura 5.14: Vazões de Ilha Solteira – Caso 4.




Figura 5.15: Geração Hidrelétrica – Caso 4.

Métrica de Dispersão Mede a variância da distância de cada membro da fronteira em relação ao seu vizinho mais próximo. Quanto menor o valor de D_S , melhor é a distribuição de soluções não-dominadas encontradas pelo algoritmo. A métrica D_S é definida como:

$$D_S = \sqrt{\frac{1}{nd} \sum_{i=1}^{nd} (\bar{d} - d_i)^2} \quad (5.3)$$

$$d_i = \min_{j, j \neq i} \left(\sum_{k=1}^m |f_i^k - f_j^k| \right) \quad (5.4)$$

$$\bar{d} = \frac{\sum_{i=1}^{nd} d_i}{nd} \quad (5.5)$$

onde: f_i^k é o valor da k -ésima função-objetivo para a i -ésima solução não-dominada; nd é o número de soluções não-dominadas encontradas; m é o número de funções-objetivo e $\bar{d}$ é a média de todos os d_i . D_S igual a zero indica que todos os membros da fronteira são equidistantes.

A natureza estocástica dos algoritmos evolutivos faz com que seja necessária a realização de várias execuções para validação dos resultados. Para cada estudo e tipo de análise foram realizadas 10 rodadas de testes. Nas comparações serão consideradas informações de cada rodada, individualmente, e informações de todo o conjunto de rodadas.

Os testes foram divididos da seguinte maneira:

- Caso 5: Custo da Complementação Térmica e Volume Final: 2 usinas
- Caso 6: Custo da Complementação Térmica e Volume Final: 2 usinas, 48 meses
- Caso 7: Custo da Complementação Térmica e Volume Final: 14 usinas
- Caso 8: Custo da Complementação Térmica e Volume Final: 35 usinas
- Caso 9: Energia Total e Mínima Potência: Nova Ponte

A seguir, é feita a descrição e análise de cada um dos casos de estudo. Em todos os casos, os parâmetros de mutação e cruzamento considerados foram os que obtiveram os melhores resultados nos casos monobjetivo (Seção 5.1): $F=0,5$ e $CR=0,9$ para o hidroNSDE, $PM=0,1$ e $PC=0,9$ para o hidroNSGA.

5.2.1 Caso 5: Custo da Complementação Térmica e Volume Final: 2 usinas

O intuito deste estudo é fazer um paralelo entre as abordagens monobjetivo e multiobjetivo. Para isto, considerou-se o mesmo caso apresentado na Seção 5.1.1: Furnas e Água Vermelha,

com horizonte de planejamento de 12 meses e demanda de 2000 *MW* mensais. O tamanho considerado para a população é de $TP = 100$ indivíduos, para ambas as abordagens.

Desta vez, os objetivos serão tratados explicitamente:

$$\text{Minimizar} \quad f_1 = \sum_{t=1}^T \left[\lambda(t) \cdot \mathcal{C}(G(t)) \right] \quad (5.6)$$

$$\text{Maximizar} \quad f_2 = \sum_{i=1}^N x(i, T) \quad (5.7)$$

Variando o número de gerações G

Os primeiros testes foram realizados com o intuito de analisar a aproximação das soluções obtidas em relação a verdadeira Fronteira de Pareto. Para isto, foram realizadas 10 rodadas de testes variando o número de gerações G em: 100, 200, 500, 1.000, 2.000, 5.000, 10.000, 20.000, 50.000 e 100.000. Foram realizadas 10 rodadas de testes considerando a uniformização do reservatório da usina a jusante (Seção 4.1) e 10 rodadas de testes sem a utilização deste operador. O intuito é, além de validar sua utilização, comparar os resultados obtidos nas duas situações.

Os resultados do hidroNSGA sem a uniformização estão apresentados na Figura 5.16, e na Figura 5.18 com a uniformização. Os resultados do hidroNSDE sem a uniformização estão apresentados na Figura 5.17 e na Figura 5.19 com a uniformização. A Tabela 5.11 apresenta o número de soluções não-dominadas encontradas e o tempo de execução de cada um dos casos.

G	hidroNSGA				hidroNSDE			
	sem uniformização		com uniformização		sem uniformização		com uniformização	
	nd	tempo (s)	nd	tempo (s)	nd	tempo (s)	nd	tempo (s)
100	36	0,724	95	0,679	88	0,551	97	0,576
200	73	1,490	91	1,307	91	1,107	97	1,144
500	85	3,649	93	3,282	96	2,758	97	2,800
1.000	85	7,238	97	6,436	94	5,459	93	5,602
2.000	89	14,382	98	13,062	96	10,576	93	11,069
5.000	89	35,644	98	32,435	95	27,105	96	27,610
10.000	93	71,686	95	63,432	94	53,246	95	54,623
20.000	96	141,921	96	127,908	93	109,048	97	108,737
50.000	93	358,203	99	320,478	92	270,932	94	277,650
100.000	96	743,555	93	650,852	95	582,453	95	557,005

Tabela 5.11: Número de soluções não-dominadas e tempo de execução (em segundos) – Caso 5.

Analisando os gráficos das soluções sem a uniformização, juntamente com a quantidade de soluções não-dominadas em cada fronteira, percebe-se que o hidroNSDE converge mais rapida-




Figura 5.16: Fronteiras não-dominadas, hidroNSGA, sem uniformização – Caso 5.




Figura 5.17: Fronteiras não-dominadas, hidroNSDE, sem uniformização – Caso 5.

mente que o hidroNSGA. Por outro lado, o hidroNSGA consegue encontrar porções da Fronteira de Pareto que o hidroNSDE não consegue: soluções Pareto-ótimas onde o valor de f_1 (custo da complementação térmica) é nulo.

A uniformização do reservatório da usina a jusante acelerou o processo de convergência, desde as primeiras gerações. Mas, novamente, apenas o hidroNSGA conseguiu obter soluções nas quais a complementação térmica é nula ($f_1=0$). Para melhor visualização das fronteiras obtidas com e sem o uso da uniformização, as Figuras 5.20 e 5.21 apresentam, para o hidroNSGA e hidroNSDE, respectivamente, as seguintes situações: $G=5.000$ com uniformização, $G=5.000$ sem uniformização, $G=100.000$ sem uniformização e $G=100.000$ com uniformização.

Analisando as Figuras 5.20 e 5.21 percebe-se que tanto para o hidroNSGA quanto para o hidroNSDE, as soluções com uniformização são um pouco melhores do que as soluções sem uniformização. Especificamente, para as soluções extremas $f_1=0$ do hidroNSGA, as soluções




Figura 5.18: Fronteiras não-dominadas, hidroNSGA, com uniformização – Caso 5.




Figura 5.19: Fronteiras não-dominadas, hidroNSDE, com uniformização – Caso 5.




Figura 5.20: Fronteiras não-dominadas, hidroNSGA – Caso 5.




Figura 5.21: Fronteiras não-dominadas, hidroNSDE – Caso 5.

sem o uso da uniformização apresentaram $f_2=28.290$, enquanto que as soluções com o uso da uniformização apresentaram $f_2=29.360$. Ou seja, com o uso da uniformização, mantendo os reservatórios das usinas a jusante cheios, além de acelerar o processo de convergência, obtêm-se soluções melhores.

Soluções não-dominadas com $G = 5.000$

As comparações que se seguem são referentes a $G=5.000$. Este número de gerações foi escolhido apenas com o intuito de apresentar uma solução extrema $f_1=0$ (no caso do hidroNSGA). Uma quantidade menor de gerações também é capaz de apresentar soluções com a mesma qualidade, como verificado nos gráficos anteriores.

Como forma de evitar o efeito da população inicial na comparação dos algoritmos, foram executadas 10 rodadas de testes para cada um dos algoritmos. As Figuras 5.22 e 5.23 apresentam o conjunto das dez fronteiras, respectivamente, do hidroNSGA e do hidroNSDE.

A seguir (Tabela 5.12), são mostrados a média e o desvio da dispersão, considerando as 10 rodadas de testes realizadas para cada abordagem. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas.

Comparando os resultados obtidos com as duas abordagens, o hidroNSDE obteve melhor tempo computacional e conseguiu obter mais soluções não-dominadas que o hidroNSGA. Por outro lado, o hidroNSGA conseguiu aproximar mais as soluções na extremidade $f_1=0$ da Fronteira de Pareto. Em relação à dispersão das soluções, ambas as abordagens tiveram comportamentos semelhantes; vale notar os valores do hidroNSGA são maiores que os valores do hidroNSDE devido às soluções obtidas nas extremidades, que estão mais espalhadas. E novamente é




Figura 5.22: Fronteiras não-dominadas, 10 rodadas, hidroNSGA – Caso 5.




Figura 5.23: Fronteiras não-dominadas, 10 rodadas, hidroNSDE – Caso 5.

$G=5.000$	hidroNSGA		hidroNSDE	
	sem uniformização	com uniformização	sem uniformização	com uniformização
média D_S	$1,66.10^3$	$1,41.10^3$	$1,44.10^3$	$1,23.10^3$
desvio D_S	244,85	153,20	476,66	196,81
nd	90	95	95	96
tempo (s)	34,862	32,168	27,216	27,603

Tabela 5.12: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 5.

possível observar que a utilização da uniformização do reservatório a jusante (Água Vermelha) promove uma melhor aproximação da Fronteira de Pareto.

Os resultados apresentados a seguir referem-se a uma das dez rodadas executadas para cada abordagem. As Figuras 5.24 e 5.26 apresentam os volumes dos reservatórios de Furnas e Água Vermelha, considerando o algoritmo hidroNSGA sem uniformização, para todas as soluções não-dominadas obtidas. Da mesma forma, as Figuras 5.25 e 5.27 apresentam os resultados do hidroNSDE. Mesmo sem a uniformização do reservatório, Água Vermelha apresentou soluções com volume útil sempre próximo de 100%. Estão destacadas nas Figuras os volumes obtidos com as duas soluções extremas da fronteira escolhida. Especialmente em relação à Água Vermelha, vale atentar ao fato de que as soluções que mais deplecionaram o volume do reservatório de Água Vermelha, são soluções extremas e dominadas por soluções encontradas com utilização da uniformização.

Com a utilização da uniformização todas as soluções não-dominadas apresentaram, tanto para o hidroNSGA quanto para o hidroNSDE, o volume do reservatório de Água Vermelha igual a 100% do volume útil, em todo o horizonte de planejamento. As Figuras 5.28 e 5.29




Figura 5.24: Soluções não-dominadas, sem uniformização: reservatório de Furnas, hidroNSGA – Caso 5.




Figura 5.25: Soluções não-dominadas, sem uniformização: reservatório de Furnas, hidroNSDE – Caso 5.




Figura 5.26: Soluções não-dominadas, sem uniformização: reservatório de Água Vermelha, hidroNSGA – Caso 5.




Figura 5.27: Soluções não-dominadas, sem uniformização: reservatório de Água Vermelha, hidroNSDE – Caso 5.

apresentam os volumes do reservatório de Furnas, com uniformização em Água Vermelha, para todas as soluções não-dominadas encontradas pelo hidroNSGA e hidroNSDE, respectivamente. O comportamento do reservatório de Furnas foi o mesmo nos quatro casos estudados.

Soluções extremas

Analisando a geração hidrelétrica total apresentada pelas duas soluções extremas, ou seja, a solução com menor valor para f_1 e a solução com maior valor para f_2 , observa-se o que já havia sido discutido anteriormente. O algoritmo hidroNSGA (Figura 5.30) consegue aproximar soluções da extremidade $f_1=0$, ou seja, complementação térmica nula, de melhor forma que o hidroNSDE (Figura 5.31). Observa-se que, para o hidroNSDE, a geração mensal, se aproximou muito da demanda de 2.000 MW, mas não a atingiu. O motivo da obtenção deste resultado, provavelmente, está no operador de mutação do hidroNSDE que trata as soluções *target* perten-




Figura 5.28: Soluções não-dominadas, com uniformização: reservatório de Furnas, hidroNSGA – Caso 5.




Figura 5.29: Soluções não-dominadas, com uniformização: reservatório de Furnas, hidroNSDE – Caso 5.

centes às fronteiras F_i , com $i > 1$. Estas soluções acabam sendo guiadas na direção de soluções que pertençam à fronteiras melhores. Uma solução para este problema poderia ser a inserção de novos indivíduos aleatórios (reinicialização) afim de explorar melhor o espaço de busca.




Figura 5.30: Geração Hidrelétrica: soluções extremas, hidroNSGA – Caso 5.

Soluções semelhantes ao caso monobjetivo

Para comparação com as soluções obtidas no caso monobjetivo (Seção 5.1), para cada uma das dez fronteiras de cada algoritmo com e sem o uso da uniformização do reservatório da usina a jusante, uma solução semelhante à obtida no caso monobjetivo foi selecionada. Ou seja, os dados a seguir, referem-se a 40 soluções que obtiveram geração hidrelétrica mensal




Figura 5.31: Geração Hidrelétrica: soluções extremas, hidroNSDE – Caso 5.

maior ou igual à média considerada⁶ no caso monobjetivo (1823,85 *MW* para o hidroGA e 1823,76 *MW* para o hidroDE) e conseguiram recuperar os volumes dos reservatórios ao final do horizonte de planejamento. A Tabela 5.13 resume os resultados de geração hidrelétrica obtidos com estas soluções: a média da geração média mensal, a média do desvio padrão da geração mensal, a média da geração hidrelétrica total (considerando todo o horizonte de planejamento). Para o mesmo conjunto de soluções também são calculadas as médias dos volumes finais dos reservatórios de cada usina (Tabela 5.14).

$G=5.000$	hidroNSGA		hidroNSDE	
	sem uniformização	com uniformização	sem uniformização	com uniformização
Média	1.852,66	1.826,33	1.850,28	1.827,53
Desvio	16,05	13,85	18,50	16,60
Total	22.231,97	21.915,95	22.203,32	21.930,32

Tabela 5.13: Geração Hidrelétrica ($\overline{MW}$) – Caso 5.

$G=5.000$	hidroNSGA		hidroNSDE	
	sem uniformização	com uniformização	sem uniformização	com uniformização
Furnas	95,64	99,63	95,63	99,45
Água Vermelha	99,46	100,00	99,72	100,00

Tabela 5.14: Médias dos Volumes Finais dos Reservatórios (em [%] do volume útil) – Caso 5.

⁶Adotando $G=150$, $F=0,5$ e $CR=0,9$ para o hidroDE, $PM=0,1$ e $PC=0,9$ para o hidroGA.

Apesar das soluções sem uniformização apresentarem maior geração hidrelétrica (média e total) e consequentemente, menor complementação térmica, as soluções com uniformização conseguem recuperar os reservatórios mais próximos de 100% do volume útil e portanto, representam soluções mais seguras operacionalmente. Além disso, as soluções com uniformização apresentaram menores desvios, ou seja, geração hidrelétrica mensal mais uniforme.

Comparando o conjunto de soluções obtidas no caso monobjetivo (Tabela 5.3) com as soluções aqui apresentadas (Tabela 5.13), na média, as soluções selecionadas das fronteiras obtiveram maiores gerações hidrelétricas média e total.

Para comparação entre as soluções obtidas com o hidroNSGA e com o hidroNSDE foram escolhidas 4 soluções do conjunto anterior, semelhantes às soluções obtidas com a formulação monobjetivo (Seção 5.1.1). As Figuras a seguir apresentam os resultados obtidos com as soluções selecionadas: volumes dos reservatórios (Figuras 5.32 e 5.33) e vazões turbinadas (Figuras 5.34 e 5.34). Os valores de f_1 (custo da complementação térmica) e f_2 (soma dos volumes finais dos reservatórios) correspondentes a cada uma destas soluções em suas respectivas fronteiras, são:

- hidroNSGA, sem uniformização: $f_1 = 337.162,67$ e $f_2 = 33.807,05$
- hidroNSGA, com uniformização: $f_1 = 345.708,25$ e $f_2 = 33.916,73$
- hidroNSDE, sem uniformização: $f_1 = 302.556,11$ e $f_2 = 33.548,11$
- hidroNSDE, com uniformização: $f_1 = 349.950,34$ e $f_2 = 33.940,92$

Nota-se novamente que as soluções sem uniformização apresentaram menores valores de f_1 . Por outro lado, as soluções com uniformização apresentaram maiores valores de f_2 .




Figura 5.32: Volume Útil (em [%]), hidroNSGA, com e sem uniformização – Caso 5.




Figura 5.33: Volume Útil (em [%]), hidroNSDE, com e sem uniformização – Caso 5.




Figura 5.34: Vazão Turbinada (em m^3/s), hidroNSGA, com e sem uniformização – Caso 5.




Figura 5.35: Vazão Turbinada (em m^3/s), hidroNSDE, com e sem uniformização – Caso 5.

Como nas soluções obtidas no caso monobjetivo, observa-se que Furnas regulariza a vazão de Água Vermelha, com ou sem a uniformização do reservatório. Isso mostra que o uso da uniformização não altera as características das soluções.

Alteração no Volume Inicial

Suponha que a usina de Furnas, como resultado de uma decisão de planejamento anterior, não tenha conseguido recuperar seu reservatório em 100%. Considere que atualmente o reservatório de Água Vermelha esteja em 100% do volume útil e o de Furnas em 75%. A vazão natural afluyente considerada é a MLT. Foram executadas 10 rodadas de cada algoritmo, com a uniformização do reservatório de Água Vermelha.

Para este caso, considerou-se $TP=100$ indivíduos e $G=500$ gerações⁷. Os resultados desta situação estão comentados a seguir.

A seguir (Tabela 5.15), a média e o desvio da dispersão, considerando as 10 rodadas de testes realizadas para cada abordagem. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas.

As fronteiras não-dominadas deste caso, obtidas com o hidroNSGA e com o hidroNSDE, estão apresentadas na Figura 5.36.

Os volumes de Furnas, representados por cada solução não-dominada de cada abordagem, estão apresentados nas Figuras 5.37 (hidroNSGA) e 5.38 (hidroNSDE). Os volumes representados pela soluções extremas de cada fronteira estão em destaque.

Analisando as soluções extremas do hidroNSGA, como garantia de que o reservatório de

⁷Com a uniformização, este número de gerações já apresenta uma boa aproximação da Fronteira. Valores maiores de G também foram testados para se chegar a esta conclusão.

$G=500$	hidroNSGA	hidroNSDE
média D_S	$9,33.10^3$	$9,58.10^3$
desvio D_S	$3,93.10^3$	$4,78.10^3$
nd	96	97
tempo (s)	2,844	2,573

Tabela 5.15: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos), com alteração no volume inicial – Caso 5.




Figura 5.36: Fronteiras não-dominadas, com alteração no volume inicial – Caso 5.

Furnas retorne a 100% do volume útil, a geração hidrelétrica mensal deve estar entre 1.390 *MW* e 1.660 *MW* (solução extrema correspondente à maximização de f_2), como mostra a Figura 5.39. O reservatório de Furnas poderá atingir 44,56% de seu volume útil, caso a geração hidrelétrica mensal esteja entre 1.860 *MW* e 1.980 *MW* (solução extrema correspondente à minimização de f_1).

Para o hidroNSDE, para que o reservatório de Furnas recupere seu volume ao final do horizonte de planejamento, a geração hidrelétrica deve estar entre 1.500 *MW* e 1.640 *MW* (solução extrema que representa a maximização de f_2), como mostra a Figura 5.40. Caso a geração hidrelétrica mensal esteja entre 1.810 *MW* e 2.000 *MW* (solução extrema que representa a minimização de f_1), o reservatório de Furnas poderá atingir 44,68% de seu volume útil.

Alteração no Volume Inicial e na Vazão Natural Afluente

Outra questão importante para o problema é a análise dos valores extremos de vazões afluentes possíveis de serem observados. Estes casos são importantes no projeto dos empreendimentos e na operação dos reservatórios. Neste caso, será considerada uma vazão natural afluente de seca: 60% da MLT. Novamente, considere que o reservatório de Água Vermelha está em 100%




Figura 5.37: Soluções não-dominadas, com alteração no volume inicial: reservatório de Furnas, hidroNSGA – Caso 5.




Figura 5.38: Soluções não-dominadas, com alteração no volume inicial: reservatório de Furnas, hidroNSDE – Caso 5.




Figura 5.39: Geração Hidrelétrica, com alteração no volume inicial: soluções extremas, hidroNSGA – Caso 5.

do volume útil e o de Furnas em 75%. Foram executadas 10 rodadas de cada algoritmo, com a uniformização do reservatório de Água Vermelha.

Para este caso novamente, considerou-se $TP=100$ indivíduos e $G=500$ gerações. Os resultados desta situação estão comentados a seguir.

A seguir (Tabela 5.16), a média e o desvio da dispersão, considerando as 10 rodadas de testes realizadas para cada abordagem. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas.

As fronteiras não-dominadas deste caso, obtidas com o hidroNSGA e com o hidroNSDE estão apresentadas na Figura 5.41. Percebe-se neste caso, como as fronteiras se distanciaram de $f_1 = 0$. Ou seja, com o volume inicial de Furnas em 75%, Água Vermelha funcionando a fio d'água e um cenário de vazão natural afluentes de seca, a decisão extrema de minimizar o




Figura 5.40: Geração Hidrelétrica, com alteração no volume inicial: soluções extremas, hidroNSDE – Caso 5.

$G=500$	hidroNSGA	hidroNSDE
média D_S	$4,45.10^4$	$4,80.10^4$
desvio D_S	$3,32.10^3$	$4,11.10^3$
nd	100	100
tempo (s)	2,584	2,585

Tabela 5.16: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos), com alteração na vazão natural afluente – Caso 5.

custo da complementação térmica é representada por $f_1 = 2,948.10^6$. Porém, esta decisão faz com que o reservatório de Furnas atinja o mínimo volume útil, como mostram as Figuras 5.42 (hidroNSGA) e 5.43 (hidroNSDE). Os volumes representados pela soluções extremas de cada fronteira estão em destaque.




Figura 5.41: Fronteiras não-dominadas, com alteração na vazão natural afluente – Caso 5.




Figura 5.42: Soluções não-dominadas, com alteração na vazão natural afluyente: reservatório de Furnas, hidroNSGA – Caso 5.




Figura 5.43: Soluções não-dominadas, com alteração na vazão natural afluyente: reservatório de Furnas, hidroNSDE – Caso 5.

Para o hidroNSGA, as soluções extremas tem geração hidrelétrica mensal entre 1.260 MW e 1.740 MW , com a minimização de f_1 , e entre 582 MW e 1.190 MW , com a maximização de f_2 (Figura 5.44). Para o hidroNSDE, uma geração hidrelétrica mensal entre 1.390 MW e 1.740 MW é obtida com a solução extrema que minimiza f_1 (Figura 5.45) e uma geração entre 621 MW e 1.150 MW é obtida com a solução extrema que maximiza f_2 .




Figura 5.44: Geração Hidrelétrica, com alteração na vazão natural afluyente: soluções extremas, hidroNSGA – Caso 5.

Especialmente nas duas últimas situações estudadas, com alteração no volume inicial e com alteração na vazão natural afluyente, situações de risco onde a segurança energética não pode ser totalmente garantida, a apresentação de múltiplas e diferentes alternativas ao decisor se torna muito importante.




Figura 5.45: Geração Hidrelétrica, com alteração na vazão natural afluente: soluções extremas, hidroNSDE – Caso 5.

5.2.2 Caso 6: Custo da Complementação Térmica e Volume Final: 2 usinas, 48 meses

O intuito deste estudo é novamente fazer um paralelo entre as abordagens monobjetivo e multiobjetivo. Para isto, considerou-se o mesmo caso apresentado na Seção 5.1.2: Furnas e Água Vermelha, com horizonte de planejamento de 48 meses e demanda de 2000 MW mensais. O tamanho considerado para a população é de $TP = 100$ indivíduos, para ambas as abordagens.

Os objetivos são tratados explicitamente:

$$\text{Minimizar} \quad f_1 = \sum_{t=1}^T \left[\lambda(t) \cdot \mathcal{C}(G(t)) \right] \quad (5.8)$$

$$\text{Maximizar} \quad f_2 = \sum_{i=1}^N x(i, T) \quad (5.9)$$

Foram executadas 10 rodadas de cada algoritmo, com e sem a uniformização do reservatório de Água Vermelha. Considerou-se $G=5.000$ gerações. A Figura 5.46 apresenta as fronteiras obtidas em cada abordagem.

A seguir (Tabela 5.17), a média e o desvio da dispersão, considerando as 10 rodadas de testes realizadas para cada abordagem, com uniformização. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas.

Os resultados apresentados a seguir, referem-se a uma das dez rodadas executadas com o hidroNSGA e com o hidroNSDE, ambas com uniformização do reservatório de Água Vermelha. As Figuras 5.47 e 5.48 apresentam os volumes dos reservatórios de Furnas obtidos com as soluções não-dominadas de cada abordagem.




Figura 5.46: Fronteiras não-dominadas, com e sem uniformização – Caso 6.

$G=5.000$	hidroNSGA	hidroNSDE
média D_S	$2,83.10^3$	$3,76.10^3$
desvio D_S	$5,04.10^2$	$2,67.10^3$
nd	95	98
tempo (s)	96,09	90,49

Tabela 5.17: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 6.




Figura 5.47: Soluções não-dominadas: reservatório de Furnas, hidroNSGA – Caso 6.

Soluções semelhantes ao caso monobjetivo

Para comparação com as soluções obtidas no caso monobjetivo (Seção 5.1), para cada uma das dez fronteiras, uma solução semelhante à obtida no caso monobjetivo foi selecionada. A Tabela 5.18 resume os resultados de geração hidrelétrica obtidos com estas soluções: a média




Figura 5.48: Soluções não-dominadas: reservatório de Furnas, hidroNSDE – Caso 6.

da geração média mensal, a média do desvio padrão da geração mensal, a média da geração hidrelétrica total (considerando todo o horizonte de planejamento).

$G=5.000$	hidroNSGA	hidroNSDE
Média	1825,01	1824,42
Desvio	20,46	26,30
Total	87600,41	87572,35

Tabela 5.18: Geração Hidrelétrica ($\overline{MW}$) – Caso 6.

Comparando o conjunto de soluções obtidas no caso monobjetivo (Tabela 5.5) com as soluções aqui apresentadas (Tabela 5.18), na média, as soluções selecionadas das fronteiras obtiveram maiores gerações hidrelétricas média e total.

Para comparação entre as soluções obtidas com o hidroNSGA e com o hidroNSDE foram escolhidas 2 soluções semelhantes às soluções obtidas com a formulação monobjetivo (Seção 5.1.2). As Figuras a seguir apresentam os resultados obtidos com as soluções selecionadas: volumes dos reservatórios (Figura 5.49) e vazões turbinadas (Figura 5.50).

Os valores de f_1 (custo da complementação térmica) e f_2 (soma dos volumes finais dos reservatórios) correspondentes a cada uma destas soluções em suas respectivas fronteiras, são:

- hidroNSGA: $f_1 = 1.186.452,73$ e $f_2 = -33.800,45$
- hidroNSDE: $f_1 = 1.189.723,69$ e $f_2 = -33.810,07$





Figura 5.49: Volume Útil (em [%]) – Caso 6.

Figura 5.50: Vazão Turbinada (em m^3/s) – Caso 6.

5.2.3 Caso 7: Custo da Complementação Térmica e Volume Final: 14 usinas

Para este estudo, considerou-se o mesmo caso apresentado na Seção 5.1.4: 8 usinas com reservatório (Emboração, Itumbiara, São Simão, Furnas, Peixoto, Marimbondo, Água Vermelha e Ilha Solteira) e 6 usinas a fio d'água (Cachoeira Dourada, Estreito, Jaguará, Igarapava, Volta Grande e Porto Colômbia), em um horizonte de planejamento de 12 meses. A demanda foi fixada em 11500 MW mensais. O tamanho considerado para a população é de $TP = 100$ indivíduos, para ambas as abordagens.

Os objetivos são tratados explicitamente:

$$\text{Minimizar} \quad f_1 = \sum_{t=1}^T \left[\lambda(t) \cdot \mathcal{C}(G(t)) \right] \quad (5.10)$$

$$\text{Maximizar} \quad f_2 = \sum_{i=1}^N x(i, T) \quad (5.11)$$

Foram executadas 10 rodadas de cada algoritmo, com a uniformização do reservatório de Ilha Solteira. Considerou-se $G=10.000$ gerações. A Figura 5.51 apresenta as fronteiras obtidas em cada caso.




Figura 5.51: Fronteiras não-dominadas – Caso 7.

A seguir (Tabela 5.19), a média e o desvio da dispersão, considerando as 10 rodadas de testes realizadas para cada abordagem. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas.

$G=10.000$	hidroNSGA	hidroNSDE
média D_S	$4,36.10^4$	$4,07.10^4$
desvio D_S	$1,92.10^4$	$1,43.10^4$
nd	66	90
tempo (s)	585,7	544,93

Tabela 5.19: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 7.

Os resultados apresentados a seguir, referem-se a uma das dez rodadas executadas com o hidroNSGA e com o hidroNSDE. As trajetórias de volume das usinas com reservatório, obtidos com as soluções não-dominadas de cada abordagem, estão apresentadas nas Figuras 5.52 e 5.53.




Figura 5.52: Volumes dos Reservatórios, hidroNSGA – Caso 7.

A função de regularização dos reservatórios das usinas a jusante são desempenhadas pelas usinas de Emborcação, Itumbiara e Furnas (Figuras 5.52 e 5.53). E esta característica é a mesma, em todas as soluções não-dominadas obtidas com as duas abordagens. O volume do reservatório de Furnas apresentou o mesmo comportamento obtido com as soluções não-dominadas do Caso 5 (Seção 5.2.1).

Durante os testes foi observado que, com o aumento da demanda, as usinas de Emborcação e Itumbiara apresentam o mesmo comportamento da usina de Furnas: soluções com maior variabilidade no volume final do reservatório. Neste caso, as soluções se distanciam de $f_1 = 0$, apresentando uma fronteira não-dominada mais extensa.




Figura 5.53: Volumes dos Reservatórios, hidroNSDE – Caso 7.

Soluções semelhantes ao caso monobjetivo

Para comparação com as soluções obtidas no caso monobjetivo (Seção 5.1), para cada uma das dez fronteiras, uma solução semelhante à obtida no caso monobjetivo foi selecionada. A Tabela 5.20 resume os resultados de geração hidrelétrica obtidos com estas soluções: a média da geração média mensal, a média do desvio padrão da geração mensal, a média da geração hidrelétrica total (considerando todo o horizonte de planejamento).

Comparando o conjunto de soluções obtidas no caso monobjetivo (Tabela 5.9) com as soluções aqui apresentadas (Tabela 5.20), os resultados de gerações hidrelétricas foram semelhantes. Porém, com um aumento no número de gerações do caso multiobjetivo, este resultado

$G=10.000$	hidroNSGA	hidroNSDE
Média	10.802,79	10.804,22
Desvio	229,36	154,51
Total	129.633,53	129.650,69

Tabela 5.20: Geração Hidrelétrica ($\overline{MW}$) – Caso 7.

ainda pode ser melhorado.

Para comparação entre as soluções obtidas com o hidroNSGA e com o hidroNSDE foram escolhidas 2 soluções semelhantes às soluções obtidas com a formulação monobjetivo (Seção 5.1.4). Estas soluções estão apresentadas, juntamente com as trajetórias de volume obtidas com o modelo HydroMax (Cicogna & Soares 2005, Cicogna 1999, Cicogna 2003) na Figura 5.54. A Figura 5.55 apresenta os resultados obtidos com as soluções selecionadas (hidroNSGA e hidroNSDE) para a vazão turbinada por Ilha Solteira.

Os valores de f_1 (custo da complementação térmica) e f_2 (soma dos volumes finais dos reservatórios) correspondentes a cada uma destas soluções em suas respectivas fronteiras, são:

- hidroNSGA: $f_1 = 5.682.957,71$ e $f_2 = -118.327,96$
- hidroNSDE: $f_1 = 5.585.050,84$ e $f_2 = -118.248,09$

5.2.4 Caso 8: Custo da Complementação Térmica e Volume Final: 35 usinas

No caso monobjetivo, uma das dificuldades encontradas para testes com um grande número de usinas foi a configuração do parâmetro de penalização $\mathcal{M}(\cdot)$. Este caso de estudo tem o intuito de testar o desempenho dos algoritmos multiobjetivo, hidroNSGA e hidroNSDE, para esta situação, já com a vantagem de não necessitar deste parâmetro adicional. O teste contempla as 35 usinas apresentadas na Figura B.1 do Apêndice B, em um horizonte de planejamento de 12 meses. A demanda foi fixada em 30.800 MW mensais. O tamanho considerado para a população é de $TP = 100$ indivíduos, para ambas as abordagens.

Os objetivos são tratados explicitamente:

$$\text{Minimizar} \quad f_1 = \sum_{t=1}^T \left[\lambda(t) \cdot \mathcal{C}(G(t)) \right] \quad (5.12)$$

$$\text{Maximizar} \quad f_2 = \sum_{i=1}^N x(i, T) \quad (5.13)$$




Figura 5.54: Volumes dos Reservatórios – Caso 7.

Foram executadas 5 rodadas de cada algoritmo, com a uniformização dos reservatórios de São Simão, Ilha Solteira e Porto Primavera. Considerou-se $G=10.000$ gerações. A Figura 5.56 apresenta as fronteiras obtidas por cada abordagem.

A seguir (Tabela 5.21), a média e o desvio da dispersão, considerando as 5 rodadas de testes realizadas para cada abordagem. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas.

Este foi o único caso estudado em que o hidroNSDE obteve um tempo computacional maior que o hidroNSGA.




Figura 5.55: Vazões de Ilha Solteira – Caso 7.




Figura 5.56: Fronteiras não-dominadas – Caso 8.

$G=10.000$	hidroNSGA	hidroNSDE
média D_S	$2,57 \cdot 10^6$	$2,23 \cdot 10^6$
desvio D_S	$2,31 \cdot 10^5$	$2,81 \cdot 10^5$
nd	98	98
tempo (s)	2.705,60	2.899,10

Tabela 5.21: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 8.

Soluções extremas

Analisando os valores extremos de f_1 , obtidos em cada rodada, na média, a recuperação do volume final do subsistema foi de 99,49% para o hidroNSGA e 99,40% para o hidroNSDE, o que correspondem, respectivamente a custos de complementação térmica iguais a $7,89 \cdot 10^8$ e $7,37 \cdot 10^8$.

Para os valores extremos de f_2 , na média, a recuperação do volume final do subsistema foi de 74,85% para o hidroNSGA e 76,33% para o hidroNSDE, o que correspondem, respectivamente a custos de complementação térmica iguais a $3,05 \cdot 10^7$ e $5,05 \cdot 10^7$.

As Figuras 5.57 e 5.58 apresentam a geração hidrelétrica total obtidas com as soluções extremas de cada algoritmo.




Figura 5.57: Geração Hidrelétrica: soluções extremas, hidroNSGA – Caso 8.




Figura 5.58: Geração Hidrelétrica: soluções extremas, hidroNSDE – Caso 8.

5.2.5 Caso 9: Energia Total e Mínima Potência: Nova Ponte

Este caso aborda um estudo com a usina hidrelétrica de Nova Ponte, com duas funções objetivo diferentes: a maximização da energia total gerada e maximização da mínima potência gerada, em um horizonte de planejamento de 12 meses. A capacidade instalada da usina é de 510 *MW* mensais. Desta vez, a vazão natural afluente considerada foi do período de maio de 1976 a abril de 1977. Para este caso, o volume inicial e o volume final do reservatório da usina foram fixados em 95% de seu volume útil. Para isto, as seguintes restrições foram adicionadas ao modelo:

$$x(i, 0) = x_{min}(i, t) + 0,95.(x_{max}(i, t) - x_{min}(i, t)) \quad (5.14)$$

$$x(i, T) = x_{min}(i, t) + 0,95.(x_{max}(i, t) - x_{min}(i, t)) \quad (5.15)$$

O tamanho considerado para a população é de $TP = 400$ indivíduos, para ambas as abordagens, por se tratar de um problema mais fortemente restrito e com poucos indivíduos factíveis nas populações iniciais. Também foi permitido que os indivíduos infactíveis pudessem ser selecionados para cruzamento e mutação (a classificação não-dominada faz com que estes indivíduos sejam menos favorecidos). O número de gerações considerado foi $G=2.500$. Foram executadas 10 rodadas de cada algoritmo.

Os objetivos são tratados explicitamente:

$$\text{Maximizar} \quad f_1 = \sum_{t=1}^T \left[H(t) \cdot \delta_c \right] \quad (5.16)$$

$$\text{Maximizar} \quad f_2 = \min_t \left[H(t) \right] \quad \forall t \in \{1, 2, \dots, T\} \quad (5.17)$$

com $\delta_c = 720$, o fator de conversão de unidades.

A Figura 5.59 apresenta as fronteiras obtidas por cada abordagem.

A seguir (Tabela 5.22), a média e o desvio da dispersão, considerando as 10 rodadas de testes realizadas para cada abordagem. Também são apresentadas as médias do tempo de execução e do número de soluções não-dominadas encontradas. O hidroNSGA conseguiu, em todas as rodadas de testes, fazer com que todas as soluções convergissem para a primeira fronteira não-dominada, além de apresentar a melhor dispersão das soluções.

Soluções extremas

Soluções extremas de uma das fronteiras do hidroNSGA e do hidroNSDE foram selecionadas para análise. As Figuras 5.60 e 5.62 apresentam a geração hidrelétrica destas soluções. Os




Figura 5.59: Fronteiras não-dominadas – Caso 9.

$G=2.500$	hidroNSGA	hidroNSDE
média D_S	29,35	92,78
desvio D_S	15,68	53,03
nd	400	371
tempo (s)	443,80	306,9

Tabela 5.22: Dispersão, número de soluções não-dominadas e tempo de execução (em segundos) – Caso 9.

respectivos volumes estão apresentados nas Figuras 5.61 e 5.63.




Figura 5.60: Geração Hidrelétrica: soluções extremas, hidroNSGA – Caso 9.




Figura 5.61: Volume útil [%]: soluções extremas, hidroNSGA – Caso 9.

Para o hidroNSGA, a solução extrema da fronteira selecionada que correspondente à maximização da mínima potência gerada, apresentou $f_2 = 288,98$ e $f_1 = 2,5293.10^6$. A solução




Figura 5.62: Geração Hidrelétrica: soluções extremas, hidroNSDE – Caso 9.




Figura 5.63: Volume útil [%]: soluções extremas, hidroNSDE – Caso 9.

extrema correspondente à maximização da energia total gerada, apresentou $f_1 = 2,5738.10^6$ e $f_2 = 171,09$. As soluções extremas da fronteira selecionada do hidroNSDE, correspondem a $f_2 = 291,26$ e $f_1 = 2,5272.10^6$ (para maximização da mínima potência gerada) e $f_1 = 2,5725.10^6$ e $f_2 = 170,90$ (para maximização da mínima potência gerada).

As soluções extremas correspondentes a maximização de f_2 apresentaram gerações hidrelétricas uniformes e aproximadamente constantes. Com isso e devido ao período seco (Figura 5.64), o reservatório de Nova Ponte foi deplecionado. Com a chegada das vazões afluentes do período úmido, o reservatório recupera novamente o nível final desejado (95%). As soluções extremas correspondentes a maximização de f_1 apresentaram gerações hidrelétricas que acompanharam o comportamento da vazão natural afluente (Figura 5.64). No período seco o reservatório sofreu um pequeno deplecionamento, mas chegou a atingir 100% no volume útil no período úmido, retornando novamente aos 95% para satisfazer a restrição do último intervalo de tempo.




Figura 5.64: Vazão Natural Afluente de Nova Ponte – Caso 9.

Ao final das gerações, os 400 indivíduos de todas as execuções do hidroNSGA e do hidroNSDE representaram soluções factíveis. O que demonstra a eficiência dos algoritmos propostos no tratamento de soluções infactíveis. As populações iniciais apresentaram de 1 a 10 indivíduos factíveis. É importante ressaltar, que as variáveis do modelo não foram fixadas para que este nível pudesse ser atingido. Apenas adicionou-se a restrição da Equação 5.15 ao problema e os algoritmos trataram eficientemente as infactibilidades de maneira que o reservatório pudesse recuperar seu volume final no nível exigido.

Conclusões e Perspectivas

Nesta tese foram propostas a adaptação e aplicação de duas Metaheurísticas Evolutivas, Algoritmos Genéticos e Evolução Diferencial, para a resolução do Problema de Planejamento da Operação de Sistemas Hidrelétricos. As abordagens propostas demonstraram possuir grande potencial na resolução deste problema, trabalhando com um conjunto de soluções, denominado população, e otimizando cada solução em paralelo. Essa característica possibilita obter como resultado final soluções distintas com boa qualidade, que podem ser usadas como alternativas. Por exemplo, maior geração hidrelétrica, porém com maior deplecionamento dos reservatórios. Isso pode ser interessante para o problema de Planejamento Hidrelétrico uma vez que esse é um problema que sofre variações no tempo. Além disso, as várias soluções factíveis e de qualidade são encontradas em uma única execução do algoritmo.

A primeira parte da tese apresentou dois algoritmos, hidroGA e hidroDE, para tratamento do problema em sua forma monobjetivo. O intuito da proposição destas abordagens foi a validação da aplicação das Metaheurísticas Evolutivas ao Problema de Planejamento Hidrelétrico, em sua forma mais “simples”, com um único objetivo. Realizada a validação e com a obtenção de resultados satisfatórios, o estudo do problema com a formulação multiobjetivo foi iniciado. Os algoritmos hidroGA e hidroDE, trataram os objetivos de minimização da complementação térmica e maximização dos volumes finais dos reservatórios de forma implícita. Isto porque não apresentaram um conjunto de soluções de compromisso (*trade-offs*), mas um conjunto de soluções que dependia do parâmetro de penalização $\mathcal{M}(\cdot)$. Variando $\mathcal{M}(\cdot)$ também é possível alternar a importância de cada objetivo. Uma dificuldade encontrada é quanto à especificação deste parâmetro com o aumento do número de usinas.

A segunda parte da tese apresentou outros dois algoritmos, hidroNSGA e hidroNSDE, para tratamento do problema em sua forma multiobjetivo. As abordagens trataram os objetivos simultaneamente de forma explícita. Ou seja, apresentaram um conjunto de soluções de com-

promisso (*trade-offs*), em uma única execução do algoritmo, sem a necessidade de nenhum parâmetro adicional para penalização ou ponderação dos objetivos. No conjunto de soluções obtido, comparando-se duas soluções, uma melhora em um dos objetivos resulta em degradação de outro.

Outra vantagem em relação a formulação multiobjetivo é a possibilidade de otimização sem nenhuma condição pré-definida a respeito do estado final dos reservatórios das usinas do subsistema, possibilitando o estudo de diferentes alternativas de planejamento: a minimização da complementação térmica, acarreta o deplecionamento dos reservatórios; a decisão de economizar água no presente está relacionada a um menor uso da geração térmica no futuro (menor custo futuro). As abordagens desta tese foram propostas com o intuito de processar e reunir o maior número de informações possível, antes de uma tomada de decisão. Dada a relevância do problema, considera-se fundamental a disponibilização de várias alternativas diferentes e de qualidade. As alternativas permitem ao decisor alcançar uma relação balanceada entre a minimização do custo de operação e, indiretamente, a minimização do custo futuro. Embora a maioria das abordagens da literatura trabalhem fixando o volume final dos reservatórios, o intuito deste trabalho foi fazer um estudo mais didático sobre o problema.

Sobre os resultados obtidos, o hidroDE apresentou geração hidrelétrica mais uniforme, obtendo, na média, menores desvios de geração. E em todos os casos monobjetivo, o hidroDE apresentou os menores tempos computacionais. No caso multiobjetivo, o hidroNSDE se aproximou mais rapidamente da Fronteira de Pareto no Caso 5 e obteve melhor aproximação no Caso 7. Por outro lado, o hidroNSGA obteve as melhores aproximações nos Casos 6 e 8, além de ter obtido soluções com $f_1=0$ (Pareto-ótimas) no Caso 5. Sobre a dispersão das soluções, os algoritmos obtiveram resultados semelhantes. Quanto ao número de soluções não-dominadas, a maior diferença entre os algoritmos foi no Caso 7, com 66 soluções do hidroNSGA e 90 soluções do hidroNSDE. O hidroNSDE obteve os melhores tempos computacionais, exceto no Caso 8 (35 usinas).

As soluções dos casos multiobjetivo semelhantes às obtidas nos casos monobjetivo conseguiram recuperar os volumes dos reservatórios, obtendo geração hidrelétrica igual ou maior que as soluções apresentadas nos casos monobjetivo. Uma característica dos algoritmos, percebida durante os testes, é a capacidade de continuar melhorando a qualidade das soluções com o passar das iterações, mesmo com a obtenção de bons resultados quantitativos. Com mais iterações, a geração hidrelétrica total torna-se mais uniforme.

Sobre o tempo computacional dos casos multiobjetivo, vale lembrar que os algoritmos otimizaram simultaneamente um conjunto de 100 soluções. Além disso, o foco dos estudos é no

planejamento, onde pode-se permitir a existência de tempos de execução maiores.

Existe a tendência das usinas a jusante funcionarem como usinas a fio d'água, mas como as vazões turbinadas por estas usinas são inicializadas aleatoriamente, isso ocorre muito lentamente. Para alguns casos, as soluções sem uniformização apresentam pequenas oscilações. Nesta situação, a verificação de uma possível uniformização permite que este processo seja acelerado.

Existem poucos trabalhos na literatura que trabalham com problemas multiobjetivo em espaços de busca fortemente restritos (Coello 2005). Entretanto, este é o caso da maioria dos problemas e aplicações do mundo real. Portanto, é necessário o estudo e desenvolvimento de metodologias que possam lidar com este tipo de problema eficientemente, como foi observado no Caso 9.

Perspectivas Futuras

As hidrelétricas apresentam incertezas para o fornecimento de energia, pois dependem das propriedades aleatórias das vazões afluentes aos seus reservatórios. Para sistemas de potência em que as hidrelétricas desempenham um papel importante, como no caso do Brasil, os efeitos aleatórios e estocásticos das vazões devem ser estudados com cuidado (dos Reis 2011).

A presença de incerteza em processos de tomada de decisão implica em imprevisibilidade do resultado da otimização, caso os efeitos das incertezas sejam negligenciados. Ao se aplicar algoritmos de otimização para tratar problemas reais, é necessário lidar com incertezas que podem degradar o desempenho de tais algoritmos. Tornar o algoritmo capaz de lidar com ambientes incertos geralmente permite atenuar os efeitos da incerteza na solução do problema (França et al. 2011).

Dentre os trabalhos futuros, serão realizadas adaptações aos Algoritmos Evolutivos propostos e implementação de novos operadores voltados para a redução dos efeitos potencialmente danosos das incertezas. O tratamento da estocasticidade das vazões afluentes, com a Otimização Robusta, será realizado como continuação desta pesquisa.

A implementação de outras metodologias de resolução, incluindo hibridizações também será considerada. Por exemplo, com a identificação e combinação das melhores características de cada abordagem (Algoritmo Genético e Evolução Diferencial).

Novos experimentos serão realizados, com diferentes combinações de conjunto de usinas e horizontes de planejamento. A característica multimodal será estudada de forma aprofundada.

A codificação adotada considerou a vazão turbinada por cada usina em cada período de tempo como variável de decisão. Codificações alternativas também podem ser consideradas:

um indivíduo representando o volume armazenado em cada reservatório em cada período de tempo. Adaptações na codificação para consideração de vertimento turbinável também será estudada.

Publicações

Berbert, P. C., Freitas Filho, L. J. R., Almeida, T. A., Carvalho, M. B., Yamakami, A. “Artificial Immune System to Find a Set of k-Spanning Trees with Low Costs and Distinct Topologies”. *In: Artificial Immune Systems - Lecture Notes in Computer Science*, de Castro, L.N., Von Zuben, F.J., Knidel, H. (eds), 1ed., Berlin: Springer, v.4628, p.395-406, 2007.

Berbert, P. C., Yamakami, A. “Algoritmo Bio-inspirado para Otimização Multiobjetivo”. *In: XLI Simpósio Brasileiro de Pesquisa Operacional (XLI SBPO)*, Porto Seguro, Bahia, Brasil, p.1836-1847, 2009.

Berbert, P. C., Yamakami, A., França, F. O. “Planejamento Hidrelétrico: Abordagem Bio-Inspirada”. *In: 9th Congress Latin American on Electricity Generation and Transmission (IX CLAGTEE)*, Mar del Plata, Argentina, 2011.

Berbert, P. C., Yamakami, A., França, F. O. “Abordagem Bio-inspirada para o problema de Planejamento Hidrelétrico”. *In: XLIII Simpósio Brasileiro de Pesquisa Operacional (XLIII SBPO)*, Ubatuba, São Paulo, Brasil, 2011.

Berbert, P. C., Yamakami, A., França, F. O. “Algoritmo Genético e Evolução Diferencial para a Resolução do Problema de Planejamento Hidrelétrico”. *In: Metaheurísticas em Pesquisa Operacional*, Rodrigues, L. C. A., Steiner, M.T.A., Lopes, H.S. (eds), Omnipax, 2012.

Submissões

Berbert, P. C., Yamakami, A., França, F. O. “Hydropower Planning: a Comparison Between Genetic Algorithms and Differential Evolution”. *In: Transactions on Power Systems*, 2012.

Bibliografia

- Abbass, H. A., Sarker, R. & Newton, C. (2001). PDE: A pareto-frontier differential evolution approach for multi-objective optimization problems, *Proceedings of Congress on Evolutionary Computation 2001 (CEC 2001)*, Piscataway, New Jersey, p. 971–978.
- Abraham, A. & Jain, L. (2005). *Evolutionary Multiobjective Optimization: Theoretical Advances and Applications*, 1 edn, Springer-Verlag, Londres, chapter Evolutionary Multiobjective Optimization, pp. 1–6.
- ANEEL (2002). Atlas de energia elétrica do Brasil – Agência Nacional de Energia Elétrica. 1ªed.
- ANEEL (2004). Ofício n.447/2004 SRG/ANEEL, Determinação da taxa de desconto para os estudos de planejamento e programação do ONS – Agência Nacional de Energia Elétrica.
- ANEEL (2005). Mais energia: Potenciais hidráulicos – Agência Nacional de Energia Elétrica. <http://www.aneel.gov.br>.
- ANEEL (2012). Informações técnicas: Linhas de transmissão – Agência Nacional de Energia Elétrica. <http://www.aneel.gov.br/area.cfm?idArea=67>.
- Bäck, T., Fogel, D. B. & Michalewicz, Z. (2000a). *Evolutionary Computation 1: Basic Algorithms and Operators*, 1 edn, Institute of Physics Publishing, Bristol, UK.
- Bäck, T., Fogel, D. B. & Michalewicz, Z. (2000b). *Evolutionary Computation 2: Advanced Algorithms and Operators*, 1 edn, Institute of Physics Publishing, Bristol, UK.
- Barros, M. L. T., Tsai, F. T. C., Yang, S., Lopes, J. E. G. & Yeh, J. W. G. (2003). Optimization of large-scale hydropower system operations, *Journal of Water Resources Planning and Management* **129**(3): 178–188.

- Barros, M., Ros, D. & Lopes, J. (2005). Objective functions for hydropower system operation, in G. Moglen (ed.), *Proceedings of Watershed 2005*, pp. 101–101.
- Bellman, R. E. (1957). *Dynamic Programming*, 1 edn, Princeton University Press, New Jersey, USA.
- Brans, J. P. & Vinke, P. H. (1985). A preference ranking organization method, the PROMETHEE method for MCDM, *Management Science* **31**: 647–656.
- Carneiro, A. A. F. M., Soares, S. & Bond, P. S. (1990). A large scale application of an optimal deterministic hydrothermal scheduling algorithm, *IEEE Transactions on Power Systems* **5**(1): 204–211.
- Carvalho, M. & Soares, S. (1987). An efficient hydrothermal scheduling algorithm, *IEEE Transactions on Power Systems* **2**(3): 537–542.
- Catalão, J. P. S., Mariano, S. J. P. S., Mendes, V. M. F. & Ferreira, L. A. F. M. (2009). Scheduling of head-sensitive cascaded hydro systems: A nonlinear approach, *IEEE Transactions on Power Systems* **24**(1): 337–346.
- Catalão, J. P. S., Pousinho, H. M. I. & Mendes, V. M. F. (2009). Mixed-integer nonlinear programming for head-dependent short-term hydro scheduling, *Proceedings of International Conference on Power Engineering, Energy and Electrical Drives (POWERENG'09)*, pp. 90–94.
- CEPEL (2003). Modelo DESSEM, manual de referência – Centro de Pesquisas de Energia Elétrica. versão 8.2.
- CEPEL (2004). Modelo DECOMP, manual de referência – Centro de Pesquisas de Energia Elétrica. versão 12.0.
- CEPEL (2007). Modelo NEWAVE, manual de referência – Centro de Pesquisas de Energia Elétrica. versão 13.0.
- Chang, L. C. & Chang, F. J. (2009). Multiobjective evolutionary algorithm for operating parallel reservoir system, *Journal of Hydrology* **377**: 12–20.
- Chen, L., McPhee, J. & Yeh, W. W. G. (2007). A diversified multiobjective GA for optimizing reservoir rule curves, *Advances in Water Resources* **30**: 1082–1093.

- Cheng, C. T., Wang, W. C., Xu, D. M. & Chau, K. W. (2008). Optimizing hydropower reservoir operation using hybrid genetic algorithm and chaos, *Water Resources Management* **22**: 895–909.
- Cicogna, M. A. (1999). *Modelo de Planejamento da Operação Energética de Sistemas Hidrotérmicos a Usinas Individualizadas Orientado por Objetos*, Dissertação de mestrado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP.
- Cicogna, M. A. (2003). *Sistema de Suporte à Decisão para o Planejamento e a Programação da Operação de Sistemas de Energia Elétrica*, Tese de doutorado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP.
- Cicogna, M. A. & Soares, S. (2003). Um sistema gerenciador de dados cadastrais para as usinas hidrelétricas brasileiras, *Anais do XV Simpósio Brasileiro de Recursos Hídricos*, pp. 1–6.
- Cicogna, M. A. & Soares, S. (2005). Hydrolab: Manual de características da produção de energia elétrica. <http://www.cose.fee.unicamp.br>.
- Clímaco, J. N., Alves, M. J. G. & Antunes, C. H. (2003). *Programação Linear Multiobjectivo: Do Modelo de Programação Linear Clássico à Consideração Explícita de Várias Funções Objectivo*, 1 edn, Imprensa da Universidade de Coimbra, Coimbra, Portugal.
- Coelho, G. P. & Von Zuben, F. J. (2006). Omni-aiNet: An immune inspired approach for omni optimization, *Proceedings of 5th International Conference on Artificial Immune Systems - Lecture Notes In Computer Science*, Springer, Oeiras, Portugal, pp. 294–308.
- Coello, C. A. C. (2002). Evolutionary multiobjective optimization:.. past, present and future. Tutorial - CINVESTAV-IPN, Depto. de Ingeniería Eléctrica, Sección de Computación.
- Coello, C. A. C. (2005). *Evolutionary Multiobjective Optimization: Theoretical Advances and Applications*, 1 edn, Springer-Verlag, Londres, chapter Recent Trends in Evolutionary Multiobjective Optimization, pp. 7–32.
- Coello, C. A. C. & Cortés, N. C. (2005a). Solving multiobjective optimization problems using an artificial immune system, *Genetic Programming and Evolvable Machines* **6**(2): 163–190.
- Coello, C. A. C. & Cortés, N. C. (2005b). Solving multiobjective optimization problems using an artificial immune system, *Genetic Programming and Evolvable Machines* **6**(2): 163–190.

- Coello, C. A. C. & Lechuga, M. S. (2002). Mopso: A proposal for multiple objective particle swarm optimization, *Proceedings of Congress on Evolutionary Computation (CEC 2002)*, IEEE Service Center, Piscataway, New Jersey, pp. 1051–1056.
- Coello, C. A. C. & Toscano-Pulido, G. (2001). *Evolutionary Multi-Criterion Optimization - Lecture Notes in Computer Science*, Vol. 1993, 1 edn, Springer, chapter A Micro-Genetic Algorithm for Multiobjective Optimization, p. 126–140.
- Corne, D. W., Knowles, J. D. & Oates, M. J. (2000). *Parallel Problem Solving from Nature - Lecture Notes in Computer Science*, Vol. 1917, 1 edn, Springer, Paris, France, chapter The Pareto Envelope-based Selection Algorithm for Multiobjective Optimization, p. 839–848.
- Cortés, N. C. (2004). *Sistema Inmune Artificial para solucionar problemas de optimización*, Tese de doutorado, Centro de Investigación y de Estudios Avanzados Del Instituto Politécnico Nacional, México.
- Costa, J. P., Maceira, M. E. P., Suanno, C. M. & Pereira, M. V. F. (1993). Modelo estratégico de geração hidrotérmica a subsistemas - newave. especificação funcional - relatório técnico, *Technical report*, Centro de Pesquisas de Energia Elétrica (CEPEL).
- de Castro, L. N. & Timmis, J. (2002). An artificial immune network for multimodal function optimization, *Proceedings of IEEE Congress on Evolutionary Computation*, May, Hawaii, pp. 699–674.
- de França, F. O., Von Zuben, F. J. & de Castro, L. N. (2005). An artificial immune network for multimodal function optimization on dynamic environments, *Proceedings of Genetic and Evolutionary Computation Conference*, ACM Press, New York, pp. 289–296.
- Deb, K. (1999). Multi-objective genetic algorithms: Problems difficulties and construction of test problems, *Evolutionary Computation* **7**(3): 205–230.
- Deb, K. (2001). *Multi-objective optimization using evolutionary algorithms*, Wiley-Interscience, Series in Systems and Optimization, New York, NY.
- Deb, K. (2011). Multi-objective optimization using evolutionary algorithms: An introduction, *Technical report*, Department of Mechanical Engineering, Indian Institute of Technology Kanpur, Kanpur, India. KanGAL Report 2011003, <http://www.iitk.ac.in/kangal/deb.htm>.
- Deb, K., Agrawal, S., Pratab, A. & Meyarivan, T. (2000). A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II, *Proceedings of VI Conference*

- Parallel Problem Solving from Nature*, Vol. 1917, Springer-Verlag, Paris, France, pp. 849–858.
- Deb, K., Agrawal, S., Pratab, A. & Meyarivan, T. (2002). A fast and elitist multi-objective genetic algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation* **6**(2): 182–197.
- Deb, K. & Gupta, H. (2006). Introducing robustness in multi-objective optimization, *Evolutionary Computation* **14**(4): 463–494.
- Deb, K. & Tiwari, S. (2005). Omni-optimizer: A procedure for single and multi-objective optimization, in C. A. C. Coello, A. Aguirre & E. Zitzler (eds), *Proceedings of 3rd Evolutionary Multi-Criterion Optimization*, LNCS, Mexico, pp. 47–61.
- Dembo, R. S. & Klincewicz, J. G. (1981). A scaled reduced gradient algorithm for network flow problems with convex separable costs, *Mathematical Programming Study* **15**(1): 125–147.
- Dias, B. H., Marcato, A. L. M., Souza, R. C., Soares, M. P., Junior, I. C. S., de Oliveira, E. J., Brandi, R. B. S. & Ramos, T. P. (2010). Stochastic dynamic programming applied to hydrothermal power systems operation planning based on the Convex Hull Algorithm, *Mathematical Problems in Engineering* **2010**(1): 1–21.
- dos Reis, L. B. (2011). *Geração de Energia Elétrica*, 2 edn, Editora Manole, Barueri, SP, Brasil.
- El-Hawary, M. E. & Christensen, G. S. (1979). *Optimal Economic Operation of Electric Power System*, 1 edn, Academic Press, New York, USA.
- Encina, A. S. A. (2006). *Despacho Ótimo de Unidades Geradoras em Sistemas Hidrelétricos via Heurística baseada em Relaxação Lagrangeana e Programação Dinâmica*, Tese de doutorado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP.
- EPE (2011). Balanço energético nacional 2011 - relatório final, ano base 2010 – Empresa de Pesquisa Energética. https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2011.pdf.
- EPE (2012). Balanço energético nacional 2012 - resultados preliminares, ano base 2011 – Empresa de Pesquisa Energética. https://ben.epe.gov.br/downloads/Resultados_Pre_BEN_2012.pdf.

- Erickson, M., Mayer, A. & Horn, J. (2001). The niched pareto genetic algorithm 2 applied to the design of groundwater remediation systems, *Proceedings of First International Conference on Evolutionary Multi-Criterion Optimization*, Vol. 1993, Springer-Verlag, p. 681–695.
- Farhat, I. A. & El-Hawary, M. E. (2009). Optimization methods applied for solving the short-term hydrothermal coordination problem, *Electric Power Systems Research* **79**: 1308–1320.
- Ferreira, P. A. V. (1999). *Otimização Multiobjetivo: Teoria e Aplicações*, Tese de livre docência, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP.
- Ferreira, V. H. & Silva, G. H. C. (2011). Natural optimization applied to medium-term hydrothermal coordination, *Proceedings of 16th International Conference on Intelligent Systems Application to Power Systems*, pp. 1–6.
- Ferrero, R. W., Rivera, J. F. & Shahidehpour, S. M. (1998). A dynamic programming two-stage algorithm for long-term hydrothermal scheduling of multireservoir systems, *IEEE Transactions on Power Systems* **13**(4): 1534–1540.
- Filgueira, J., Greco, S. & Ehrgott, M. (2005). *Multicriteria decision analysis: state of the art Surveys*, 1 edn, Springer Science Business Media Inc.
- Fonseca, C. M. & Fleming, P. J. (1993). Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization, in S. Forrest (ed.), *Proceedings of Fifth International Conference on Genetic Algorithms*, San Mateo, Califórnia, pp. 416–423.
- França, F. O., Gonçalves, A. R. & Von Zuben, F. J. (2011). Otimização em ambientes dinâmicos e incertos. Notas de aula.
- Francato, A. L. (1997). *Contribuição ao Estudo das Propriedades Ótimas da Operação de Sistemas Hidroelétricos*, Dissertação de mestrado, Faculdade de Engenharia Civil, Universidade Estadual de Campinas, SP.
- Freschi, F. & Repetto, M. (2005). Multiobjective optimization by a modified artificial immune system algorithm, *Proceedings of 4th International Conference on Artificial Immune Systems - Lecture Notes In Computer Science*, Springer, Banff, Alberta, Canadá, pp. 248–261.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*, 1 edn, Addison-Wesley, Reading, USA.

- Horn, J., Nafpliotis, N. & Goldberg, D. E. (1994). A niched pareto genetic algorithm for multiobjective optimization, *Proceedings of First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence*, IEEE Press, Piscataway, New Jersey, pp. 82–87.
- Iorio, A. W. & Li, X. (2004). Solving rotated multi-objective optimization problems using differential evolution, *Proceedings of Advances in Artificial Intelligence*, LNCS, p. 861–872.
- Jothiprakash, V. & Shanti, G. (2006). Single reservoir operating policies using genetic algorithm, *Water Resources Management* **20**: 917–929.
- Jothiprakash, V. & Shanti, G. (2009). Comparison of policies derived from stochastic dynamic programming and genetic algorithm models, *Water Resources Management* **23**: 1563–1580.
- Kennedy, J. & Eberhart, R. (1995). Particle swarm optimization, *Proceedings of IEEE International Conference on Neural Networks*, Perth, Australia, pp. 1942–1948.
- Kligerman, A. S. (2009). *Um sistema de apoio à decisão bicritério para o planejamento da operação energética*, Tese de doutorado, Instituto de Computação, Universidade Federal Fluminense, RJ.
- Knowles, J., Corne, D. & Deb, K. (2008). *Multiobjective Problem Solving from Nature: From Concepts to Applications*, 1 edn, Springer-Verlag, Berlin.
- Knowles, J. D. & Corne, D. W. (2000). Approximating the nondominated front using the pareto archived evolution strategy, *Evolutionary Computation* **8**(2): 149–172.
- Ko, S., Fontane, D. & Labadie, J. (1992). Multiobjective optimization of reservoir systems operations, *Water Resources Bulletin* **28**(1): 111–127.
- Kumar, D. N. & Reddy, M. J. (2007). Multipurpose reservoir operation using particle swarm optimization, *Journal of Water Resources Planning and Management* **133**(1): 192–201.
- Labadie, J. W. (2004). Optimal operation of multireservoir systems: State-of-the-art review, *Journal of Water Resources Planning and Management* **130**(2): 93–111.
- Leite, P. T., Carneiro, A. A. F. M. & Carvalho, A. C. P. L. F. (2002). Energetic operation planning using genetic algorithms, *IEEE Transactions on Power Systems* **17**(1): 173–179.

- Leite, P. T., Carneiro, A. A. F. M. & Carvalho, A. C. P. L. F. (2006). Aplicação de algoritmos genéticos na determinação da operação ótima de sistemas hidrotérmicos de potência, *Revista Controle & Automação* **17**(1): 81–88.
- Leite, P. T. & Carvalho, A. C. P. L. F. (2006). Hybrid genetic algorithm applied to the determination of the optimal operation of hydrothermal systems, *Proceedings of Ninth Brazilian Symposium on Neural Networks (SBRN'06)*, pp. 1–6.
- Li, X. G. & Wei, X. (2008). An improved genetic algorithm-simulated annealing hybrid algorithm for the optimization of multiple reservoirs, *Water Resources Management* **22**: 1031–1049.
- Lopes, J. E. G. (2007). *Modelo de Planejamento da Operação de Sistemas Hidrotérmicos de Produção de Energia Elétrica*, Tese de doutorado, PHD, Escola Politécnica da Universidade Estadual de São Paulo, SP.
- Luenberger, D. G. (1984). *Linear and Nonlinear Programming*, Addison-Wesley Publishing Co.
- Madavan, N. K. (2002). Multiobjective optimization using a pareto differential evolution approach, *Proceedings of Congress on Evolutionary Computation 2002 (CEC 2002)*, Piscataway, New Jersey, p. 1145–1150.
- Man, K. F., Tang, K. S. & Kwong, S. (1996). Genetic algorithms: Concepts and applications, *IEEE Transactions on Industrial Electronics* **43**(5): 519–534.
- Marcato, A. L. M. (2002). *Representação Híbrida de Sistemas Equivalentes e Individualizados para o Planejamento da Operação de Médio Prazo de Sistemas de Potência de Grande Porte*, Tese de doutorado, DEE, PUC-RJ.
- Mezura-Montes, E., Reyes-Sierra, M. & Coello, C. A. C. (2008). *Advances in Differential Evolution*, Springer, Berlin, chapter Multi-Objective Optimization using Differential Evolution: A Survey of the State-of-the-Art, pp. 173–196.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*, 3 edn, Springer-Verlag, Berlin, Germany.
- Nascimento, L. S. V., Reis Júnior, D. S. & Martins, E. S. P. R. (2007). Comparação de algoritmos evolucionários na otimização multiobjetivo de sistemas de reservatórios, *Anais do XVII Simpósio Brasileiro de Recursos Hídricos*.
- Oliveira, G. G. & Soares, S. (1995). A second-order network flow algorithm for hydrothermal scheduling, *IEEE Transactions on Power Systems* **10**(3): 1635–1641.

- Orero, S. O. & Irving, M. R. (1998). A genetic algorithm modeling framework and solution technique for short term optimal hydrothermal scheduling, *IEEE Transactions on Power Systems* **13**(2).
- Osyczka, A. (1985). Multicriteria optimization for engineering desing, *Design Optimization* p. 193–227.
- Park, J. B., Park, Y. M., Won, J. R. & Lee, K. Y. (2000). An improved genetic algorithm for generation expansion planning, *IEEE Transactions on Power Systems* **15**(3): 916–922.
- Pedrosa, P. & Lopes, A. (2007). Contribuições da associação brasileira dos agentes comercializadores de energia elétrica (abraceel) à consulta pública aneel 008/2007. <http://www.aneel.gov.br>.
- Pereira Junior, A. O. (2005). *Operação independente por subsistemas: comportamento estratégico para a geração no Sistema Elétrico Brasileiro*, Tese de doutorado, COPPE, Universidade Federal do Rio de Janeiro, RJ.
- Pereira, M. V. F., Cunha, S. H. F., Terry, L. A. & Mossé, A. (1990). Modelos computacionais para o planejamento e operação de sistemas hidrotérmicos de grande porte, *Revista Controle & Automação* **1**(1): 31–41.
- Pereira, M. V. F. & Pinto, L. M. V. G. (1985). Stochastic optimization of a multireservoir hydroelectric system: A decomposition approach, *Water Resources Research* **21**(6): 779–792.
- Price, K. V., Storn, R. M. & Lampinen, J. A. (2005). *Differential evolution: a practical approach to global optimization*, 1 edn, Springer-Verlag, Berlin, Germany.
- Reddy, M. J. & Kumar, D. N. (2006). Optimal reservoir operation using multi-objective evolutionary algorithm, *Water Resources Management* **20**: 861–878.
- Robič, T. & Filipič, B. (2005). Demo: Differential evolution for multiobjective optimization, in C. A. C. Coello, A. Aguirre & E. Zitzler (eds), *Proceedings of 3rd Evolutionary Multi-Criterion Optimization*, LNCS, Mexico, p. 520–533.
- Rosenthal, R. E. (1981). A nonlinear network flow algorithm for maximization of benefits in a hydroelectric power system, *Operations Research* **29**(4): 763–785.
- Sawaragi, Y., Nakayama, H. & Tanino, T. (1985). *Theory of Multiobjective Optimization*, 1 edn, Academic Press, Orlando, Florida, USA.

- Schaffer, J. D. (1984). *Multiple Objective Optimization with Vector Evaluated Genetic Algorithms*, Tese de doutorado, Vanderbilt University, Nashville, Tennessee.
- Schott, J. R. (1995). *Fault Tolerant Design Using Single and Multicriteria Genetic Algorithm Optimization*, Dissertação de mestrado, Department of Aeronautics and Astronautics, Massachusetts Institute of Technology, Cambridge, Massachusetts.
- Scola, L. A., Neto, O. M., Takahashi, R. H. C. & Cerqueira, S. A. A. G. (2011a). *Computação Evolucionária em Problemas de Engenharia*, Omnipax, chapter Otimização Multiobjetivo da Operação de uma Usina Hidroelétrica, pp. 73–88.
- Scola, L. A., Neto, O. M., Takahashi, R. H. C. & Cerqueira, S. A. A. G. (2011b). Multi-objective optimal multiple reservoir operation, *Proceedings of IEEE Congress in Evolutionary Computation*, pp. 1927–1933.
- Sherkat, V., Moslehi, K., Campo, R. & Lo, E. (1985). Stochastic long term hydrothermal optimization for a multireservoir system, *IEEE Transactions on Power Apparatus and Systems* **104**(8): 2040–2050.
- Sinha, N., Chakraborty, R. & Chattopadhyay, P. K. (2003). Fast evolutionary programming techniques for short-term hydrothermal scheduling, *IEEE Transactions on Power Systems* **18**(1): 214–220.
- Soares, S. & Carneiro, A. A. F. M. (1991). Optimal operation of reservoirs for electric generation, *IEEE Transactions on Power Delivery* **6**(3): 1101–1107.
- Srinivas, N. & Deb, K. (1994). Multiobjective optimization using nondominated sorting in genetic algorithms, *Evolutionary Computation* **2**(3): 221–248.
- Stedinger, J. R., Sule, B. F. & Loucks, D. P. (1984). Stochastic dynamic programming models for reservoir operation optimization, *Water Resources Research* **20**(11): 1499–1505.
- Storn, R. & Price, K. (1997). Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces, *Journal of Global Optimization* **11**(1): 341–359.
- Toro, F., Ros, E., Mota, S. & Ortega, J. (2006). Evolutionary algorithms for multiobjective and multimodal optimization of diagnostic schemes, *IEEE Transactions on Biomedical Engineering* **53**(2): 178–189.

- Toscano, A. E. (2009). *Comparação entre os modelos NEWAVE e ODIN no planejamento energético do Sistema Interligado Nacional*, Dissertação de mestrado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP.
- Toscano-Pulido, G., Santana-Quintero, L. V. & Coello, C. A. C. (2007). Emopso: A multi-objective particle swarm optimizer with emphasis on efficiency, *Evolutionary Multi-Criterion Optimization* **4403**: 272–285.
- Wong, K. P. & Wong, Y. W. (1994). Short-term hydrothermal scheduling part i: simulated annealing approach, *IEEE Proceedings of Generation, Transmission and Distribution*, Vol. 141.
- Yeh, W. (1985). Reservoir management and operations models: a state-of-the-art review, *Water Resources Research* **21**(12): 1797–1818.
- Zambelli, M., Siqueira, T. G., Cicogna, M. & Soares, S. (2006). Deterministic versus stochastic models for long term hydrothermal scheduling, *IEEE Power Engineering Society General Meeting*.
- Zambon, R. C. (2008). *Planejamento da Operação de Sistemas Hidrotérmicos de Grande Porte*, Tese de doutorado, Escola Politécnica da Universidade de São Paulo, Universidade de São Paulo, SP.
- Zancheta, M. N. (2005). *As Consequências Socio, Econômico e Ambientais da Troca do óleo Combustível por Gás Natural, na Usina Termoelétrica Piratininga*, Tese de doutorado, Instituto de Pesquisas Energéticas e Nucleares, São Paulo.
- Zitzler, E., Laumanns, M. & Thiele, L. (2001). Spea2: Improving the strength pareto evolutionary algorithm - technical report 103, *Technical report*, Computer Engineering and Networks Laboratory (TIK), Swiss Federal Institute of Technology (ETH) Zurich, Zurich, Switzerland.
- Zitzler, E. & Thiele, L. (1999). Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach, *IEEE Transactions on Evolutionary Computation* **3**(4): 257–271.
- Zoumas, C. E., Bakirtzis, A. G., Theoharis, J. B. & Petridis, V. (2004). A genetic algorithm solution approach to the hydrothermal coordination problem, *IEEE Transactions on Power Systems* **19**(2): 1356–1364.

Resultados do Modelo HydroMax

A seguir, os resultados do HydroMax (Cicogna 1999, Cicogna 2003, Cicogna & Soares 2005) utilizados para validação qualitativa e quantitativa dos algoritmos propostos nesta tese.

Operação em Cascata: Furnas e Água Vermelha Com minimização do custo da Complementação Térmica.




Figura A.1: Vazões de Furnas, HydroMax – Caso 1.




Figura A.2: Vazões de Água Vermelha, HydroMax – Caso 1.




Figura A.3: Volumes dos Reservatórios, HydroMax – Caso 1.

Média	1.800,18
Desvio	3,38
Total	21.602,20

Tabela A.1: Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 1.

Horizonte de Planejamento de 48 meses Com minimização do custo da Complementação Térmica.




Figura A.4: Volumes dos Reservatórios, HydroMax – Caso 2.

Média	1.801,14
Desvio	3,64
Total	86.454,80

Tabela A.2: Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 2.

Usina a Fio d’água Com minimização do custo da Complementação Térmica.




Figura A.5: Volumes dos Reservatórios, HydroMax – Caso 3.

Média	2.397,27
Desvio	18,38
Total	28.767,20

Tabela A.3: Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 3.

14 Usinas Com minimização do custo da Complementação Térmica.




Figura A.6: Volumes dos Reservatórios, HydroMax – Caso 4.

Média	10.367,03
Desvio	51,98
Total	124.408,30

Tabela A.4: Geração Hidrelétrica ($\overline{MW}$), HydroMax – Caso 4.

Nova Ponte Com maximização da geração hidrelétrica.




Figura A.7: Geração Hidrelétrica, HydroMax – Caso 9.




Figura A.8: Volume útil [%], HydroMax – Caso 9.

Energia Total	$2,54.10^6$
Mínima Potência	180,5

Tabela A.5: Energia total (MWh) e Mínima potência ($\overline{MW}$), referentes à geração hidrelétrica $H(t)$ maximizada, HydroMax – Caso 9.

Apêndice B

Usinas Hidrelétricas dos Estudos de Caso




Figura B.1: 35 usinas hidrelétricas da região Sudeste - Brasil.