

TESE DE DOUTORADO Nº 188

**OTIMIZAÇÃO MULTIOBJETIVO EVOLUTIVA DA OPERAÇÃO DE SISTEMAS DE
RESERVATÓRIOS MULTIUSOS**

Luis Antônio Scola

DATA DA DEFESA: 18/07/2014

UNIVERSIDADE FEDERAL DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Luís Antônio Scola

**Otimização Multiobjetivo Evolutiva da Operação de
Sistemas de Reservatórios Multiusos**

TESE DE DOUTORADO

Orientador: Ricardo Hiroshi Caldeira Takahashi (MAT/UFMG)

Co-Orientador: Oriane Magela Neto (*in memoriam*)

Belo Horizonte, julho de 2014

S422o

Scola, Luis Antônio.

Otimização multiobjetivo evolutiva da operação de sistemas de reservatórios multiusos [manuscrito] / Luis Antônio Scola. - 2014. xviii, 100 f., enc.: il.

Orientador: Ricardo Hiroshi Caldeira Takahashi.

Tese (doutorado) Universidade Federal de Minas Gerais, Escola de Engenharia.

Anexos: f. 97-100.

Bibliografia: f. 92-96.

1. Engenharia elétrica - Teses. 2. Algoritmos genéticos - Teses. I. Takahashi, Ricardo Hiroshi Caldeira. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 621.3(043)

**"Otimização Multiobjetivo Evolutiva da Operação de
Sistemas de Reservatórios Multiusos"**

Luis Antônio Scola


Tese de Doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Doutor em Engenharia Elétrica.

Aprovada em 18 de julho de 2014.

Por:




Prof. Dr. Ricardo Hiroshi Caldeira Takahashi
DMAT (UFMG) - Orientador



Prof. Dr. Rodney Rezende Saldanha
DEE (UFMG)




Prof. Dr. Eduardo Gontijo Carrano
DEE (UFMG)



Prof. Dr. Anderson Ribeiro Duarte
Dep. de Estatística (UFOP)



Prof. Dr. Elizabeth Fialho Wanner
Departamento de Computação (CEFET/MG)



Prof. Dr. Sérgio Augusto Araújo da Gama Cerqueira
Dep. de Engenharia Mecânica (UFSJ)

LUÍS ANTÔNIO SCOLA

Otimização Multiobjetivo Evolutiva da Operação de Sistemas de Reservatórios Multiusos

TEXTO DE DOUTORADO SUBMETIDO À BANCA EXAMINADORA DESIGNADA PELO
COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA
UNIVERSIDADE FEDERAL DE MINAS GERAIS, COMO REQUISITO FINAL PARA A
OBTENÇÃO DO TÍTULO DE DOUTOR EM ENGENHARIA ELÉTRICA.

Orientador: Ricardo Hiroshi Caldeira Takahashi (MAT/UFMG)

Co-Orientador: Oriane Magela Neto (*in memoriam*)

Belo Horizonte, julho de 2014

Dedicatória

Para Geunice, Isabella e Pedro.

E a meus pais, Claudina e Sebastião(in memoriam).

Agradecimentos

Primeiramente, agradeço ao meu grande amigo, professor e co-orientador Oriane M. Neto, pelo incentivo e longas conversas, me levando a desejar coisas que nem imaginava para minha vida profissional, e por que não pessoal.

Ao meu grande e inestimável amigo Sérgio Cerqueira (o Serjão), pela inspiração, pelas inúmeras horas de dedicação na orientação deste trabalho, pela paciência e ensinamentos e principalmente por ter acreditado em mim.

Ao meu orientador Ricardo Takahashi, pela orientação, incentivo e paciência dedicados ao longo desses anos de labuta.

A minha família, pelo amparo e compreensão das longas horas de ausência.

A Universidade Federal de São João del Rei-UFSJ, pela oportunidade concedida e pelo apoio por intermédio do programa PROSER/PROGP/UFSJ.

Ao DCTEF/UFSJ pela confiança e nova oportunidade de qualificação.

Aos professores do PPGEE/UFGM, em especial ao Rodney pelo estímulo no estudo do tema de minha tese.

Ao casal dos grandes companheiros Jacqueline e Guillermo pelo inestimável apoio num momento de cansaço e necessidade.

A FAPEMIG pelo apoio financeiro através do PMCD em parte do trabalho.

Em especial aos amigos Lenir, Livia e Lucas pelo apoio que só eles sabem o quanto.

E a todos que de alguma forma contribuíram para que esse trabalho fosse realizado.

A minha sogra, Dona Linda, por ter nos apoiado cuidando de meu filho Pedro na nossa ausência.

A Mônica Mondaini, pela disponibilidade e presteza na revisão gramatical e ortográfica.

Resumo

Nesta tese propôs-se uma abordagem multiobjetivo evolutiva, usando como base o clássico algoritmo NSGA-II para a otimização da operação de sistemas de reservatórios interligados, com múltiplos usos para a água, considerando a geração de hidroeletricidade e o controle da navegabilidade de um trecho de rio. O algoritmo foi adaptado com a finalidade de superar características específicas do problema. A principal modificação, com implicações na melhoria do desempenho do algoritmo para tratar a formulação clássica do problema, foi a mudança no esquema de codificação das variáveis de decisão, permitindo, assim, a manipulação implícita de várias restrições do problema original.

Partindo da formulação clássica foram propostas três alternativas de tratamento das restrições, que culminaram num modelo de otimização irrestrito e limitado, usando novas variáveis de decisão, as frações de volume disponíveis mensalmente. O algoritmo proposto foi aplicado primeiro a um reservatório, considerando dois objetivos ligados à geração de energia, e a um subsistema do sistema elétrico brasileiro, composto por cinco reservatórios com cinco centrais hidroelétricas.

Para este conjunto de reservatórios foi aplicada a análise multiobjetivo para quatro diferentes cenários, avaliando o desempenho do algoritmo para dois objetivos de geração de energia elétrica e, num dos cenários, avaliou-se a inclusão de um terceiro objetivo, ligado a navegabilidade de um trecho de rio entre dois reservatórios.

Os resultados obtidos mostram que a metodologia proposta supera os problemas de perda de diversidade e convergência prematura encontrados na implementação do problema nas variáveis de decisão originais.

As informações geradas pela otimização ilustram a utilidade no processo de tomada de decisão no planejamento da operação de sistemas de reservatórios. Os resultados mostram, igualmente, que se pode quantificar o custo de qualquer novo uso da água, em termos do custo de oportunidade, que pode ser medido pelo retorno financeiro da venda da energia produzida.

Palavras Chave: Geração de Energia, Planejamento Hidroelétrico, Otimização Multiobjetivo, Algoritmos Evolutivos, Algoritmos Genéticos

Abstract

An evolutionary multiobjective optimization approach, based on NSGA-II classic algorithm, for the study of multiple water usages in multiple interlinked reservoirs, including both power generation objectives and of navigability on the river, was proposed in this thesis. The algorithm was adapted in order to cope with specific problem feature. The main modification, which caused the major enhancement in the algorithm performance, is a new encoding scheme that allows the implicit handling of most of the constraints involved in the problem.

Starting from classic formulation, three alternatives for constraints treatment were proposed culminating in an unconstrained and limited optimization model by using a new decision variable: monthly available volume fraction. The algorithm proposed was firstly applied to one reservoir system, considering two objectives linked to energy generation. Finally, the algorithm proposed was applied to a subsystem of the Brazilian electric system, composed of five reservoirs with five hydroelectric power stations.

For this last case, a multiobjective analysis for four different scenarios was applied allowing the assessment of the algorithm's performance, related to energy generation objectives and, in another scenario, the inclusion of a third one, which involves the navigability on the river between two reservoirs. The obtained results showed that the proposed methodology overcomes the problems of diversity loss and premature convergence, problems encountered in the implementation of the original decision variables.

The information generated by the optimization algorithm, demonstrated the usefulness in the making-decision process in planning the operation of reservoirs systems. The results showed that it is possible to quantify the cost of any new use of water, in terms of opportunity cost, which can be measured by financial return from the sellings of energy produced.

Keywords: Power Generation, Hydropower Planning, Multiobjective Optimization, Evolutive Algorithm, Genetics Algorithm

Lista de Figuras

FIGURA 1	Fontes da matriz de energia elétrica brasileira	2
FIGURA 2	Representação gráfica da relação de dominância entre soluções	18
FIGURA 3	Método da soma ponderada de objetivos	23
FIGURA 4	Método ε -restrito	24
FIGURA 5	Funcionamento geral do NSGA-II.	31
FIGURA 6	Cálculo da crowding distance.	33
FIGURA 7	Hidroelétrica de Itumbiara	39
FIGURA 8	Esquema de uma hidroelétrica	39
FIGURA 9	Classificação dos volumes de um reservatório	41
FIGURA 10	Esquema de composição das vazões afluentes em cada reservatório. .	43
FIGURA 11	Curvas de Potência e Vazão x Queda líquida de uma turbina	44
FIGURA 12	Distribuição de probabilidades Beta.	53
FIGURA 13	Limites superior e inferior para o volume do reservatório em cada intervalo de tempo	56
FIGURA 14	Estatística das vazões naturais mensais de nova Ponte (1931-2012) .	60
FIGURA 15	Conjuntos eficientes para 8 execuções da formulação básica, com 400 indivíduos e 5000 gerações	61
FIGURA 16	Conjuntos eficientes para 21 execuções da formulação da redução do domínio das variáveis de decisão, com 400 indivíduos e 2500 gerações	62
FIGURA 17	Conjuntos eficientes para 21 execuções da formulação irrestrita, com 400 indivíduos e 2500 gerações	63
FIGURA 18	Conjuntos eficientes para cada execução das formulações da redução de domínio das variáveis de decisão e da irrestrita, com as respectivas	

frentes de Pareto combinadas	63
FIGURA 19 Potência mensal gerada e volume do reservatório para o ponto extremo com a menor mínima potência gerada e a maior geração de energia .	64
FIGURA 20 Potência mensal gerada e volume do reservatório para o ponto extremo com a maior mínima potência gerada e a menor geração de energia .	65
FIGURA 21 Esquema do micro sistema das cinco centrais.	66
FIGURA 22 Vazões naturais médias mensais em m^3/s no reservatório de Itumbiara-GO, no período entre os anos de 1931 e 2012	67
FIGURA 23 Estatística das vazões naturais mensais de Itumbiara (1931-2012) ..	67
FIGURA 24 Resultados para o caso 1976-77, conjuntos eficientes de 30 rodadas, com 400 indivíduos e 50.000 gerações, para diferentes probabilidades de mutação, 35% em preto, 50% em azul, e 65% em verde. Em vermelho, está representado o resultado de uma única rodada, com a população inicial obtida da combinação dos conjuntos eficientes de rodadas com 400 indivíduos e 25.000 gerações.	69
FIGURA 25 Resultados para o caso 2000-01, em preto apresentam-se os conjuntos eficientes para 30 rodadas com 400 indivíduos e 50.000 gerações. Em vermelho, o conjunto eficiente para uma única rodada, com 400 indivíduos e 25.000 gerações, mas com a população inicial obtida da combinação destas soluções eficientes	70
FIGURA 26 Resultados caso 1976-77. Boxplot sobre o Conjunto Pareto das variáveis mensais de decisão (α) para cada central hidroelétrica.	71
FIGURA 27 Resultados caso 2000-01 . Boxplot sobre o Conjunto Pareto das variáveis mensais de decisão (α) para cada central hidroelétrica.	72
FIGURA 28 Comparação do desempenho dos operadores de mutação por indivíduo, curvas em vermelho, e por variável, curvas em azul, aplicado ao sistema de cinco usinas para 400 indivíduos e 1500 gerações. Também em vermelho a curva de Pareto de referência descrita na Figura (24) ...	73
FIGURA 29 Influência do tamanho da população na metodologia.	74
FIGURA 30 Influência da probabilidade de cruzamento com população de 1000 indivíduos, probabilidade de mutação de 10%, raio de mutação dividido	

por 6 e extrapolação dos extremos no cruzamento em 80%.	75
FIGURA 31 Influência da probabilidade de mutação na metodologia para uma população de 800 indivíduos.	76
FIGURA 32 Influência do fator K na amplitude de variação da mutação de uma população de 800 indivíduos na metodologia.	77
FIGURA 33 Influência da extrapolação dos extremos do segmento linear que une os indivíduos pais no cruzamento.	78
FIGURA 34 Desempenho dos melhores e piores resultados para as três combinações de parâmetros mais eficientes nos testes de sensibilidade do algoritmo genético.	79
FIGURA 35 Curvas de Pareto do desempenho elétrico do subsistema de cinco usinas resultantes da concatenação das soluções eficientes de 10 execuções do algoritmo, para cada uma das as três combinações de parâmetros definidas na análise de sensibilidade.	80
FIGURA 36 Curva de Pareto formada pela combinação de todas as soluções eficientes para 10 execuções do algoritmo para cada um dos três grupos de parâmetros de melhor desempenho na otimização do subsistema de cinco usinas (cada cor representa um conjunto de parâmetros do AG).	81
FIGURA 37 Influência da navegabilidade sobre as curvas de Pareto do subsistema estudado, a curva em vermelho corresponde a uma vazão turbinada mínima de $275\text{m}^3/\text{s}$, a curva em laranja um valor de $250\text{m}^3/\text{s}$, a curva em roxo $225\text{m}^3/\text{s}$, em magenta $218,5\text{m}^3/\text{s}$, em azul $200\text{m}^3/\text{s}$, em ciano $187,5\text{m}^3/\text{s}$, em verde claro $175\text{m}^3/\text{s}$ e em verde escuro $125\text{m}^3/\text{s}$	82
FIGURA 38 Influência da navegabilidade na curva de receita para o subsistema de cinco usinas.	83
FIGURA 39 Valor máximo de receita para cada condição de navegabilidade.	84
FIGURA 40 Resultados caso 1976-77. Influência nas curvas de Pareto para diferentes frações iniciais do volume máximo para cada reservatório do subsistema.	85
FIGURA 41 Resultados caso 1976-77. Influência nas curvas de Pareto para dois diferentes períodos de otimização do subsistema de cinco reservatórios.	86

FIGURA 42	Resultados caso 2000-2002. Influência nas curvas de Pareto para dois diferentes períodos de otimização do subsistema de cinco reservatórios.	87
FIGURA 43	Estudo de sensibilidade aos parâmetros do algoritmo genético, conjunto dos melhores e piores resultados encontrados em 10 execuções, variando-se todos os parâmetros.	97
FIGURA 44	Parte A - Legenda do estudo de sensibilidade aos parâmetros do algoritmo genético, conjunto dos melhores e piores resultados encontrados em 10 execuções, variando-se todos os parâmetros.	98
FIGURA 45	Parte B - Legenda do estudo de sensibilidade aos parâmetros do algoritmo genético, conjunto dos melhores e piores resultados encontrados em 10 execuções, variando-se todos os parâmetros.	99
FIGURA 46	Esquema das usinas hidroelétricas brasileiras componentes do SIN	100

Lista de Tabelas

TABELA 1	Capacidade por fonte de energia instalada no Brasil	2
TABELA 2	Capacidade instalada no Brasil, por região e por fonte	2
TABELA 3	Capacidade instalada de geração de energia elétrica no Brasil em %, por região e por fonte	3
TABELA 4	Potencial hidráulico brasileiro por região em %	3
TABELA 5	Coefficientes do polinômio para a função produtividade ξ_i	68
TABELA 6	Limites para os parâmetros operacionais das cinco hidroelétricas e seus reservatórios.	68
TABELA 7	Conjunto de parâmetros do algoritmo genético definidos pela análise de sensibilidade.	79

Lista de Símbolos

$\vec{f}$	Vetor de objetivos
$\vec{x}$ e $\vec{y}$	Vetores de variáveis de decisão
$x_i^{(L)}$	Limite inferior para a i-ésima variável de decisão
$x_i^{(U)}$	Limite superior para a i-ésima variável de decisão
g_j	j-ésima restrição de desigualdade
h_k	k-ésima restrição de desigualdade
N_{var}	Dimensão do espaço de variáveis de decisão
$\mathcal{X}$	Região de busca
$\mathcal{F}_x$	Região factível
N_{obj}	Dimensão do espaço de objetivos
$\mathcal{Y}$	Espaço de objetivos
$\vec{x}_1 \prec \vec{x}_2$	Relação de dominância
$\mathcal{P}$	Conjunto de soluções
$\mathcal{P}'$	Conjunto Pareto-ótimo
w_i	Peso associado ao objetivo i
ε_i	restrição para o objetivo f_i
N_{ind}	Número de indivíduos da população
$\mathcal{F}$	Frente de Pareto
g	geração g
N_{iter}	Número de gerações

P_g	g -ésima população de indivíduos pais
Q_g	g -ésima população de indivíduos filhos
R_g	União de P_g com Q_g
$f_m^{\max}$	Valor máximo da m -ésima função objetivo
$f_m^{\min}$	Valor mínimo da m -ésima função objetivo
$\prec_n$	Operador de comparação de distância de aglomeração
n_p	Número de soluções que dominam a solução p
S_p	Conjunto das soluções dominadas pela solução p
$\dot{W}_{i,t}$	Potência média da usina i no intervalo de tempo t
$\eta_{i,t}$	Eficiência média combinada grupos turbinas/geradores, da usina i no intervalo de tempo t [-]
$Q_{i,t}^T$	Vazão turbinada na usina i e no intervalo de tempo t [m^3/s]
γ_w	Peso específico da água [N/m^3]
$h_{i,t}$	Altura de queda bruta da usina i e no intervalo de tempo t [m]
$\xi_{i,t}$	Função produtividade da usina i e no intervalo de tempo t [$MW.s/m^3$]
Q^v	Vazão vertida na usina i e no intervalo de tempo t [m^3/s]
$Q_{i,t}^a$	Vazão afluente ao reservatório i no intervalo de tempo t [m^3/s]
U	Conjunto de reservatórios imediatamente a montante do reservatório i
$Q_{i,t}^d$	Vazão defluente do reservatório i no intervalo de tempo t [m^3/s]
$Q_{i,t}^I$	Vazão incremental ao reservatório i no intervalo de tempo t [m^3/s]
$V_i^{\min}$	Volume mínimo do reservatório da usina i [hm^3]
$V_i^{\max}$	Volume máximo do reservatório da usina i [hm^3]
$\dot{W}_i^{\max}$	Potência máxima da usina i [MW]
$Q_i^{T,\max}$	Vazão turbinada máxima da usina i [m^3/s]

$Q_i^{\text{turb max}}$	Vazão de engolimento máximo da usina i [m^3/s]
$V_{i,0}, V_{i,N}$	Volumes inicial e final do reservatório i [hm^3]
D_c	Demanda de energia contratada (energia firme ou assegurada) [MWh]
p_t	Preço esperado no mercado de energia [$R\$/MW$]
$S_{i,t}$	Volume meta do reservatório i no intervalo de tempo t [hm^3]
$Qab_{i,t}$	vazão desviada do reservatório i e no intervalo de tempo t para o abastecimento [m^3/s]
$Dab_{i,t}$	Demanda de água no reservatório i , no intervalo de tempo t [m^3/s]
$Q_{i,t}^{cc}$	Vazão limite a jusante do reservatório i no intervalo de tempo t [m^3/s]

Lista de Índices

i	Identifica o reservatório
t	Intervalo de tempo [mês]
M	Número de intervalos de tempo
N	Número de reservatórios
CE	Complementação de energia
VERT	Vertida
C	Contratada
cc	Controle de cheia

Lista de Acrônimos

PD Programação Dinâmica

PL Programação Linear

PNL Programação Não Linear

AE Algoritmo Evolutivo

AG Algoritmo Genético

PE Programação Evolucionária

PG Programação Genética

PDDDI Programação Dinâmica Discreta Incremental

SLGA Self-Learning Genetic Algorithm

SOM Self Organization Map

VNS Variable Neighborhood Search

SA Simulated Annealing

HDGA Hypercubic Distributed Genetic Algorithm

AGC Algoritmo Genético de Caos

ONS Operador Nacional do Sistema Elétrico

SIN Sistema Interligado Nacional

Sumário

1	Prolegômenos	1
1.1	Introdução	1
1.2	Caracterização do Problema	4
1.3	Objetivos	5
1.4	Estrutura da Tese	5
2	Revisão da Literatura	7
3	Otimização Multiobjetivo e Métodos de Solução.	15
3.1	Definição do Problema de Otimização Multiobjetivo	15
3.2	Métodos de Solução para Otimização Multiobjetivo	20
3.2.1	Métodos de Solução Clássicos	21
3.2.2	Métodos de Solução Evolutivos	25
3.3	Algoritmos Genéticos	27
3.4	Algoritmo Evolutivo Multiobjetivo NSGA II	29
4	Construção do Modelo	37
4.1	Usinas Hidroelétricas	38
4.2	Reservatórios	40
4.3	Modelo Matemático do Sistema	42
4.3.1	Geração de Potência	42
4.3.2	Restrições	42
4.3.2.1	Conservação da Massa	43

4.3.2.2	Limites Operacionais	44
4.4	Modelo de Otimização do Sistema	46
4.4.1	Funções Objetivo de Geração de Hidroeletricidade	46
4.4.1.1	Maximizar a Potência Média Gerada	46
4.4.1.2	Maximizar a Mínima Potência Gerada	47
4.4.1.3	Minimizar a Complementação da Energia	47
4.4.1.4	Minimizar a Energia Vertida	47
4.4.1.5	Maximizar o Lucro Derivado da Energia Secundária	48
4.4.2	Outras Funções Objetivo	48
4.4.2.1	Maximização da Vazão Defluente Mínima-Navegabilidade	48
4.4.2.2	Minimizar o Desvio da Meta de Volume Armazenado	49
4.4.2.3	Suprimento de água para abastecimento de cidades, indústrias e irrigação	49
4.4.2.4	Controle de Cheias	49
5	Proposta desenvolvida	51
5.1	Modificações ao NSGA-II	51
5.1.1	Operadores	51
5.1.1.1	Cruzamento	52
5.1.1.2	Mutação	52
5.2	Evolução de Alternativas no Tratamento das Restrições	54
5.2.1	Redução do Número de Indivíduos Ineficazes na População Inicial	54
5.2.2	Redução do Domínio das Variáveis de Decisão	55
5.2.3	Formulação Irrestrita	55
6	Experimentos Computacionais, Resultados e Análises	58
6.1	Análise do Caso do Sistema com um único Reservatório	59
6.1.1	Detalhamento do Caso	59

6.1.2	Resultados e Análises	60
6.2	A Bacia com Cinco Reservatórios	65
6.2.1	Aplicação da Formulação Irrestrita a Múltiplos Reservatórios	68
6.2.2	Análise de Sensibilidade	73
6.2.2.1	Conclusões da Análise de Sensibilidade	77
6.3	Estudos de Cenários	78
6.3.1	Cenário 1 - Considerações na Geração de Hidroeletricidade	79
6.3.2	Cenário 2 - Considerações Socioambientais	80
6.3.3	Cenário 3 - Considerações Sobre Segurança e Robustez Energéticas	83
6.3.4	Cenário 4 - Otimização de longo prazo versus a otimização obtida pela combinação das soluções ótimas dos anos em separado	85
7	Contribuições da Tese e Trabalhos Futuros	88
7.1	Conclusões	88
7.2	Contribuições	90
7.3	Sugestão para Trabalhos Futuros	91
	Referências	92
	Apêndices	97

1 *Prolegômenos*

1.1 Introdução

Um dos grandes desafios atuais para a humanidade é a produção de energia elétrica em escala suficiente para a satisfação das necessidades humanas e para impulsionar o seu desenvolvimento econômico e social. As fontes utilizadas nos processos de conversão são oriundas da natureza, podendo variar entre combustíveis derivados de petróleo, gás, carvão, biomassa, hidráulica, nuclear, eólica, oceânica, solar, geotérmica, e outras. Aliado ao desafio da obtenção de energia elétrica em quantidade suficiente, está a importante questão da agressividade ambiental para obtê-la ou utilizá-la.

A composição da matriz energética varia muito de país para país. Nos ricos em recursos hídricos, como o Brasil, grande parte de suas malhas geradoras de eletricidade é baseada neste recurso. A utilização da água como fonte de energia é relativamente limpa e renovável, contudo à medida em que são utilizados os locais com maior potencial de aproveitamento hidroelétrico, combinado com os crescentes usos concorrentes da água, a expansão do sistema torna-se mais cara e problemática.

No Brasil, a geração de energia elétrica no ano de 2012 alcançou a marca de 552,5 *TWh*, valor 3,9% superior ao ano de 2011. As importações líquidas de energia elétrica foram de 40,3 *TWh* no mesmo ano, totalizando uma oferta interna de energia elétrica de 592,8 *TWh* contra um consumo total de 498,4 *TWh*, com um acréscimo de 4,4% em relação a oferta no ano de 2011 (EPE, 2013).

A principal fonte na matriz de oferta de energia elétrica no Brasil é a hidráulica, com 76,9% da geração total (Figura 1).

Em 2012, com um acréscimo de aproximadamente 3,8 *GW* na capacidade instalada das centrais de geração de energia elétrica do Brasil, alcançou-se 120.973 *MW* (vide Tabela 1). Desta expansão, 47,8% foram em centrais hidráulicas, ao passo que centrais térmicas, cujos combustíveis englobam a biomassa e os fósseis, incluindo o gás natural, derivados de




FIGURA 1: Composição das fontes da matriz de oferta de energia elétrica brasileira (EPE, 2012)

TABELA 1: Capacidade instalada de geração de energia elétrica no Brasil em *MW* por fonte (EPE, 2013)

Hidráulica	Térmica	Eólica	Nuclear	Total
84.294	32.778	1.894	2.007	120.973

petróleo e o carvão mineral (e seus derivados), cresceram 40% da capacidade expandida. Por fim, as centrais eólicas foram responsáveis pelos 12,2% restantes do aumento na matriz de oferta nacional de energia elétrica.

A Tabela 2 apresenta a capacidade instalada de geração de energia elétrica em *MW* por fonte e região, ao passo que a Tabela 3 apresenta o percentual de distribuição por fonte e região desta capacidade instalada.

O potencial hidráulico brasileiro está estimado em 244.974 *MW*, segundo Balanço Energético Nacional 2013, dos quais 35,4% estão em operação e 7,7% em construção (EPE, 2013). Entende-se por potencial hidráulico, o potencial que pode ser tecnicamente e

TABELA 2: Capacidade instalada de geração de energia elétrica no Brasil em *MW*, por região e por fonte (EPE, 2013)

Região	Hidráulica	Térmica	Eólica	Nuclear	Total
Norte	12.761	4.174	0	0	16.935
Nordeste	11.311	7.265	1.212	0	19.788
Sudeste	24.819	13.372	29	2.007	40.227
Sul	23.906	4.837	653	0	29.396
Centro-Oeste	11.498	3.130	0	0	14.627

TABELA 3: Capacidade instalada de geração de energia elétrica no Brasil em %, por região e por fonte (EPE, 2013)

Região	Hidráulica	Térmica	Eólica	Nuclear	Total
Norte	15,1	12,7	0	0	14
Nordeste	13,4	22,2	64	0	16,4
Sudeste	29,4	40,8	1,5	100	33,3
Sul	28,4	14,8	34,5	0	24,3
Centro-Oeste	13,6	9,5	0	0	12,1

TABELA 4: Potencial hidráulico brasileiro por região em % (EPE, 2013)

Norte	Nordeste	Sudeste	Sul	Centro-Oeste
40,4	9	17,8	16,8	16,1

economicamente explorado nas condições atuais da tecnologia. Embora os potenciais mais significativos se encontrem em regiões mais afastadas dos principais centros consumidores da região sudeste, além de sujeitos a fortes restrições ambientais, é esperado que nos próximos anos ainda, ao menos 50% da expansão da malha geradora do país seja de origem hidráulica. A Tabela 4 apresenta a distribuição por regiões do potencial hidráulico remanescente brasileiro.

Contudo, deve-se considerar os dados relativos ao potencial hidráulico remanescente com cautela, pois os mesmos não levam em conta restrições legais e ambientais (REIS, 2011).

Nesse sentido, modelos de análise de sistemas hídricos envolvem estudos de planejamento e de operação de sistemas de reservatórios. Os modelos de planejamento têm por finalidade determinar a dimensão, a localização e o número de reservatórios necessários, enquanto que os modelos de operação incluem estudos de reavaliação da política de operação para reservatórios já existentes.

Os sistemas de reservatórios podem ser de um único ou de múltiplos reservatórios, associados em série e/ou em paralelo (KIM, 2005).

Esses sistemas são compostos de maneira geral por: reservatórios, canais, túneis, tubulações, estações de bombeamento, centrais hidroelétricas, sistemas de suprimento de água para consumo urbano, industrial e irrigação. Sistemas deste tipo podem suprir necessidades para o consumo humano, industrial e de irrigação, a produção de hidroeletricidade, o controle de enchentes, a navegação e outras finalidades ecológicas, o que ilustra os múltiplos usos que podem ser dados à água de um reservatório.

O gerenciamento destes sistemas de reservatórios, do ponto de vista do planejamento e da operação é desafiador, uma vez que o problema envolve muitas variáveis complexas como afluências, armazenamentos, transferências intra e/ou inter bacias de rios, entre outras.

1.2 Caracterização do Problema

Atualmente é evidente a necessidade de ferramentas para auxiliar aos gestores de recursos hídricos, em especial dos sistemas de reservatórios, na busca de decisões ótimas para o uso eficiente da água. Das diversas ferramentas que vêm sendo utilizadas destacam-se os modelos de simulação e de otimização.

Os modelos de simulação descrevem a operação do sistema no espaço e no tempo, com o objetivo de descrever da forma mais detalhada possível o comportamento real do sistema e de fornecer informações para avaliar o desempenho.

Por outro lado, os modelos de otimização procuram identificar a solução ótima da chamada função objetivo no caso da análise mono-objetivo ou, na análise multiobjetivo, um conjunto de soluções eficientes que verificam diferentes relações de compromisso entre as funções objetivo, que fomentam o processo de tomada de decisão. Ambos os modelos estão sujeitos a um conjunto de restrições de ordem física ou operacional.

O problema de otimização da operação de um sistema de múltiplos reservatórios é um problema de tratamento complexo devido (LABADIE, 2004; HAKIMI-ASIABAR *et al.*, 2010; RANI; MOREIRA, 2010):

- às características naturalmente multiobjetivo, considerando os múltiplos usos da água;
- à não linearidade das funções objetivo e/ou das restrições;
- ao caráter dinâmico devido à interdependência entre os estágios de tempo;
- à não convexidade das funções;
- às diversas restrições de ordem física e operacional;
- ao acoplamento hidráulico entre os reservatórios, a montante e a jusante, e;
- ao caráter estocástico das afluências aos reservatórios.

No tratamento deste problema, tem-se utilizados métodos determinísticos, como a programação linear, a programação dinâmica, os métodos de busca baseados no gradiente das funções objetivo ou métodos evolutivos como a programação genética, o *simulated annealing*, os algoritmos genéticos e os de enxames de partículas. Cada uma destas classes de métodos apresenta limitações inerentes. Diversas tentativas de superar essas dificuldades são apresentadas na literatura da área como uma terceira classe de métodos híbridos proposta por diferentes pesquisadores.

A utilização do método de algoritmos genéticos no problema de otimização multiobjetivo de sistemas de múltiplos reservatórios, apresenta limitações ligadas a dificuldade de gerar indivíduos factíveis, perda de diversidade da população e de convergência prematura. Neste trabalho será proposta uma alternativa, visando superar estas limitações por meio da mudança das variáveis de decisão modificando o modelo clássico utilizado.

1.3 Objetivos

O objetivo principal deste trabalho é desenvolver uma metodologia para a otimização multiobjetivo da operação mensal de um sistema de reservatórios com múltiplos usos da água, dando especial ênfase à geração hidroelétrica, empregando uma nova abordagem no tratamento das restrições da conservação da massa e dos limites para o volume dos reservatórios, com o intuito de reduzir a perda de diversidade da população de soluções no avanço do algoritmo genético e consequente convergência prematura.

Um segundo objetivo é considerar outro uso para a água dos reservatórios concomitantemente à geração de energia, ligado à questão da navegabilidade de um trecho de um rio entre dois reservatórios, para avaliar a relação de *trade-off* entre os objetivos e fomentar o processo de tomada de decisão.

1.4 Estrutura da Tese

A estrutura deste trabalho segue a seguinte organização:

- O primeiro capítulo apresenta características gerais da matriz energética nacional e do problema do planejamento hidroelétrico.
- No segundo capítulo é apresentada uma revisão bibliográfica de trabalhos que abordam a otimização da operação de sistemas de reservatórios.

- O capítulo três apresenta a formulação do problema multiobjetivo e os principais métodos para a solução do problema multiobjetivo.
- No capítulo quatro é apresentada a construção dos modelos matemático e de otimização do problema abordado.
- No capítulo cinco é apresentada a metodologia proposta.
- No sexto capítulo são apresentados os resultados e análises da aplicação da metodologia proposta a um sistema de um único e de cinco reservatórios.
- No sétimo capítulo são apresentados as contribuições desta tese e as futuras proposições.
- Finalmente, são apresentadas as referências bibliográficas que nortearam a realização deste trabalho.

2 *Revisão da Literatura*

Poucas áreas na aplicação de modelos de otimização têm uma história tão rica e diversa quanto a dos estudos de otimização na operação de sistemas de reservatórios. Desde a década de sessenta do século passado, figuram na literatura centenas de artigos aplicando métodos determinísticos ao problema, tais como, diversas variações da programação linear e dinâmica, métodos de direção de busca baseados no gradiente, dentre outros (LABADIE, 2004).

Antes do emprego da otimização, a operação de sistemas de reservatórios era baseada em procedimentos heurísticos, em regras abrangentes e no julgamento altamente subjetivo do operador do sistema, que baseava suas decisões das descargas dos reservatórios, no nível do volume armazenado, nas condições hidrológicas, nas demandas e na época do ano. Os termos, curvas guia ou curvas regra (do inglês *guide curve* ou *rule curve*), denotam um conjunto de regras que definem o nível do reservatório e os mecanismos que determinam as descargas em função do volume do reservatório. Contudo, a utilização destes procedimentos, não permite que seja otimizada a operação do sistema em função de mudanças das condições predominantes (HAKIMI-ASIABAR *et al.*, 2010).

Nos anos sessenta começam a surgir os primeiros estudos da otimização da operação de reservatórios e de sistemas de reservatórios de água (YOUNG, 1967). O problema da otimização de sistemas multi reservatórios não possui uma solução ótima global, exceto para o modelo teórico de quatro reservatórios proposto por Larson (1968), utilizando programação dinâmica (PD). Esta configuração de reservatórios passou a ser adotada como uma solução *benchmark* para o problema no desenvolver dos trabalhos da área.

O problema de otimização do planejamento operacional de sistemas de reservatórios é complexo e envolve muitas variáveis de decisão e múltiplos usos ou finalidades para a água dos reservatórios, tais como: a utilização para a geração de energia elétrica, a irrigação, as demandas urbanas e industriais e as tão importantes necessidades voltadas para a preservação e conservação ambiental. Considerando as múltiplas finalidades para a água,

o problema, na maioria das vezes, deve ser tratado com múltiplos objetivos conflitantes (RANI; MOREIRA, 2010; HAKIMI-ASIABAR *et al.*, 2010).

Os trabalhos iniciais a apresentar o tratamento multiobjetivo abordam o problema por meio da técnica da soma ponderada de objetivos (BARROS *et al.*, 2003) e do método ϵ -restrito, que considera o uso de objetivos como restrições (KO *et al.*, 1992). Labadie (2004) e Rani e Moreira (2010) destacam, ainda, a importância e a capacidade dos chamados métodos de “inteligência computacional”, onde se enquadram os métodos evolutivos no tratamento de problemas de múltiplos objetivos, escopo do presente trabalho.

Labadie (2004), em seu importante trabalho de revisão, aponta que o desestímulo por razões sociais, ecológicas e econômicas, a construção de novos projetos de grande escala de reservatórios de água, em países desenvolvidos e emergentes, exige que as atenções concentrem-se na melhora da eficiência operacional dos reservatórios existentes, maximizando os benéficos do uso desses projetos.

A otimização dos múltiplos usos da água dos sistemas de reservatórios, requer o emprego de ferramentas computacionais para fornecer informações racionais, fomentando o processo de tomada das decisões operacionais. Nesta revisão o autor identifica o estado da arte na otimização de operações e do gerenciamento de sistemas de reservatórios, e considera as direções futuras para pesquisas.

Os métodos de otimização desenvolvidos para superar características como a alta dimensionalidade, as características dinâmicas, as não-linearidades e estocasticidade dos sistemas de reservatórios, foram examinados considerando as formulações mono e multiobjetivos. Aplicações de métodos de programação heurística e algoritmos evolutivos e genéticos foram descritos junto com a aplicação de redes neurais e sistemas baseados em lógica *fuzzy* para inferir regras de operação de sistemas de reservatórios.

Lima e Lanna (2005) realizam um levantamento, ou melhor, uma atualização no estado da arte no uso de modelos matemáticos na análise de recursos hídricos, mostrando o grande desenvolvimento apresentado, sobretudo após os anos sessenta, impulsionados pelo advento do avanço tecnológico na área computacional. Revisam, principalmente, os métodos empregados na otimização da operação de sistemas de reservatórios. Em tal revisão adota-se uma classificação com relação as características das variáveis estudadas, se determinísticas ou estocásticas. Os métodos considerados pelos autores foram os de programação linear, dinâmica, não-linear e de simulação.

Rani e Moreira (2010) apresentam uma revisão sobre as diferentes modelagens de

otimização, simulação e o uso combinado das duas, em problemas de operação de sistemas de reservatórios. Os autores indicam que quando combinados os métodos de otimização e de simulação alcança-se melhores resultados que quando aplicados individualmente. Em adição às técnicas de otimização clássicas é abordada a aplicação e o escopo de técnicas de inteligência computacional, tais como: computação evolucionária, teoria dos conjuntos *fuzzy* e redes neurais artificiais em estudos de operação do sistema de reservatórios.

A classificação dos modelos de otimização pode ser feita de acordo com a técnica empregada e as características das variáveis utilizadas (se determinísticas ou estocásticas). De um modo geral, pode-se dividir os trabalhos desenvolvidos na literatura em três grandes classes de métodos: métodos matemáticos, métodos evolucionários e, recentemente, os métodos híbridos (HAKIMI-ASIABAR *et al.*, 2010).

A revisão enfatiza o tratamento multiobjetivo da otimização da operação de sistemas de reservatórios, por meio da aplicação de algoritmos genéticos multiobjetivo.

Dentro da utilização de métodos matemáticos, na otimização de políticas operacionais para sistemas de reservatórios, diferentes trabalhos de revisão da literatura (YEH, 1985; WURBS, 1993; LABADIE, 2004) relatam inúmeros trabalhos utilizando versões de programação linear, não linear e dinâmica. Destaca-se o trabalho de Barros *et al.* (2003), no qual se propõe um modelo de otimização mensal, chamado SISOPT, desenvolvido para otimizar as operações do sistema hidroelétrico brasileiro, um dos maiores do planeta e responsável pela maior parte da energia elétrica produzida no Brasil.

O tamanho do sistema hidroelétrico brasileiro e as não-linearidades do modelo, formulado em programação não-linear (PNL), impõem um verdadeiro desafio para os modeladores do processo. Com o intuito de avaliar a influência das não-linearidades do modelo, este foi linearizado e resolvido por meio da soma ponderada de seis objetivos. Realizou-se uma comparação dos resultados obtidos a partir dos modelos linearizado e não linearizados. Os resultados mostram que o modelo linearizado é apropriado para fins de planejamento.

A partir desses resultados, o modelo PL poderia ser utilizado, por exemplo, em estudos de expansão de capacidade do sistema, a fim de explorar várias configurações de parâmetros em conexão com estudos de viabilidade, onde os detalhes na variação do volume de armazenamento não são tão importantes quanto a produção de energia.

As técnicas de computação evolucionária, no contexto do problema, foram desenvolvidas buscando superar as complexidades na otimização de sistemas de reservatórios como o caráter multiobjetivo, as incertezas nas afluências, as não linearidades e as desconti-

nuidades, que limitam a utilização de métodos matemáticos. Estas técnicas, também conhecidas como métodos de busca heurísticos, envolvem principalmente algoritmos de otimização meta-heurísticos tais como: algoritmos evolucionários (AE), compreendendo os algoritmos genéticos (AG), a programação evolucionária (PE) e a programação genética (PG); a inteligência de enxames, compreendendo os algoritmos de colônia de formigas, enxame de partículas; o *simulated annealing* e a busca tabu.

Os métodos ligados à computação evolucionária desenvolveram-se significativamente nos últimos anos, principalmente na otimização multiobjetivo (RANI; MOREIRA, 2010), além da facilidade de adaptação às características de incerteza na afluência, que os habilita com grande vantagem no tratamento de problemas ligados à otimização de sistemas de reservatórios.

A utilização dos algoritmos genéticos, no estudo de sistemas de reservatórios, foi introduzida por Esat e Hall (1994), que comparou o esforço computacional dos AG's com a programação dinâmica discreta diferencial incremental (PDDDI), mostrando que o tempo computacional e os requisitos de memória crescem linearmente com os primeiros e exponencialmente para os últimos. Os autores relatam, ainda, que quando a dimensão do sistema excede a 4 reservatórios os AG's apresentam desempenho superior.

Estes algoritmos oferecem, dentre outros atrativos, a generalidade, por requererem pouquíssimas modificações na adaptação de um problema para outro, e pela facilidade de implementação para o processamento paralelo. Contudo, em problemas altamente restritos apresentam a dificuldade de que grande parte da população das soluções se torna infactível, sendo esta considerada como a maior desvantagem dos AG's.

Uma técnica para o tratamento de restrições foi proposta por Deb (2000) e aplicada por Ahmed e Sarma (2005), na otimização de um reservatório com múltiplos usos da água: geração de eletricidade e irrigação. Os resultados alcançados foram comparados com os do modelo de programação dinâmica estocástica, mostrando desempenho competitivo e promissor para a otimização operacional de sistemas de reservatórios.

Wardlaw e Sharif (1999) propõem várias formulações alternativas de algoritmos genéticos para sistemas de reservatórios, que foram avaliados utilizando o problema determinístico, de horizonte de tempo finito, de quatro reservatórios proposto por Larson (1968). Tais formulações tinham como objetivo avaliar esquemas alternativos de representação, de seleção, de cruzamento e de mutação em aplicações práticas. Com este estudo, conclui-se que a abordagem mais promissora com o uso de um algoritmo genético para o problema de quatro reservatórios compreende o uso de codificação real, seleção por torneio, cruzamento

uniforme e mutação uniforme modificada.

A codificação real opera de forma significativamente mais rápida do que a codificação binária e produz melhores resultados, alcançando o ponto de ótimo global conhecido para o problema de quatro reservatórios. Um problema não-linear de quatro reservatórios foi também considerado com um horizonte de tempo estendido. Os resultados demonstraram que um algoritmo genético pode ser satisfatoriamente utilizado em operações em tempo real com afliências estocasticamente geradas. Um problema mais complexo com dez reservatórios também foi considerado, e os resultados produzidos pelo algoritmo genético foram comparados aos previamente publicados (MURRAY; YAKOWITZ, 1979) que utilizaram PL.

A utilização do AG alcança a mesma qualidade, embora com um esforço computacional maior. O aumento no tempo de execução não foi atribuído à introdução das não linearidades nas funções objetivos ou de restrições. A abordagem do algoritmo genético é robusta e pode ser facilmente aplicada para sistemas complexos. Ela tem potencial para ser uma alternativa às abordagens de programação dinâmica estocástica.

Em um estudo de caso sobre a aplicação de AG a um sistema multi reservatórios, localizados na Indonésia, Sharif e Wardlaw (2000) consideram três configurações: a existente e dois cenários futuros. Desenvolveu-se um modelo de algoritmo genético para a otimização dos sistemas de reservatórios, facilmente adaptável para qualquer outro sistema de reservatórios, sendo esta generalidade uma vantagem prática da abordagem algoritmo genético. Os resultados foram comparados com os produzidos pela programação dinâmica discreta diferencial. Para cada caso considerado neste estudo, os resultados alcançados pelo algoritmo genético estão muito próximos do ponto de ótimo, o que demonstra a robustez da técnica. Ao contrário dos métodos baseados em programação dinâmica, não é necessária a discretização de variáveis de estado. Além disso, não há nenhuma exigência de estado inicial para a busca usando um algoritmo genético.

Os métodos híbridos constituem uma linha de pesquisa que tenta superar a deficiência do processo de intensificação, da baixa taxa de convergência e da imprecisão na busca local associadas aos métodos evolucionários, incorporando um método de direção de busca local baseado no cálculo do gradiente da função objetivo ou na sua aproximação. Hakimi-Asiabar *et al.* (2010) desenvolvem uma implementação híbrida de algoritmo genético, denominada *Self-Learning Genetic Algorithm - SLGA*, como uma versão melhorada do algoritmo genético multiobjetivo baseado em *SOM - SBMOGA*, que usa os algoritmos *Self Organization Map - SOM* (HAKIMI-ASIABAR *et al.*, 2009) e *Variable neighborhood Search - VNS* (HANSEN; MLADENIVIC, 2001) para adicionar uma memória ao algoritmo genético

e melhorar a sua precisão de busca local. *SOM* é uma rede neural de aprendizagem com possibilidade de melhoria na eficiência de processamento de dados dos algoritmos. O uso do *VNS*, por sua vez, pode melhorar a eficiência de busca local em algoritmos evolucionários.

O modelo proposto foi usado para desenvolver políticas operacionais ótimas no sistema de múltiplos reservatórios de Karoon-Dez, no Irã, que abriga um quinto do total de recursos da água de superfície do país. As funções objetivo definidas para esse problema são: o suprimento de demanda de água, a geração de energia hidroelétrica e o controle da qualidade da água a jusante no rio.

Chiu *et al.* (2007) apresentam uma nova abordagem para a otimização da política operacional de um reservatório, introduzindo lógica *fuzzy* num algoritmo evolucionário híbrido, de algoritmo genético (AG) com *Simulated Annealing* (SA). Na análise, os objetivos e restrições de operação do reservatório são transformados pela programação *fuzzy* para otimizar o grau de satisfação. No procedimento de pesquisa híbrido, o algoritmo genético realiza a busca global enquanto que o algoritmo *Simulated Annealing* realiza a busca local. Esta abordagem foi empregada na otimização da política operacional do Reservatório Shihmen em Taiwan, utilizando dados de afluência históricos. Os resultados foram comparados com regras operacionais existentes para o reservatório, demonstrando que: (1) poderiam ser formuladas através de programação *fuzzy* regras operacionais dentro de um grau de satisfação α entre os usuários e as restrições e (2) o algoritmo híbrido AG-SA obteve desempenho superior às regras operacionais. O método híbrido AG-SA aumenta a probabilidade de encontrar a solução ótima e reduzir o tempo de processamento.

Chen e Chang (2007) propõem um algoritmo genético de codificação real, *Hypercubic Distributed Genetic Algorithm (HDGA)*, para otimizar a operação de sistema de reservatórios. Um algoritmo genético convencional AG fica, muitas vezes, preso a ótimos locais durante o processo de otimização. Para evitar a convergência prematura e obter soluções quase ótimas, o HDGA foi projetado para ter várias subpopulações, que são processadas usando AG's separados e paralelos. A topologia hipercúbica, com um pequeno diâmetro, espalha boas soluções rapidamente ao longo de todas as subpopulações. Um mecanismo de migração, que troca cromossomos entre as subpopulações durante a otimização conjunta, mantém a diversidade, portanto, evita uma convergência prematura a um único ótimo local.

Primeiramente, abordou-se o problema de referência de de quatro reservatórios (LARSON, 1968), para investigar a aplicabilidade e a eficácia do método proposto. Os resulta-

dos mostram que a solução ótima global conhecida pode ser alcançada de forma eficaz e estável pelo HDGA. Em seguida, aplicou-se ao planejamento de um sistema de múltiplos reservatórios, no norte de Taiwan, encontrando resultados superiores ao AG convencional. Observa-se, portanto, que o HDGA minimiza o déficit de água deste sistema de reservatórios e fornece um desempenho superior em termos de obtenção de valores mais baixos da função objetivo e de evitar soluções ótimas locais.

Em 2008, Cheng *et al.* (2008) propõe um novo algoritmo genético de caos (AGC), baseado no algoritmo de otimização de caos (AOC) e em algoritmo genético AG, que faz uso da ergodicidade e da aleatoriedade interna de iterações do algoritmo do caos para superar a convergência prematura para um ótimo local e aumentar a velocidade do algoritmo genético.

O AGC integra a poderosa capacidade de busca global do AG com a poderosa capacidade de busca local do AOC. Os resultados dos testes indicam que o AGC pode melhorar a velocidade de convergência e precisão da solução. A média de energia originada pelo AGC é melhor, assim como a velocidade de convergência que, não só supera em muito a da programação dinâmica, mas também supera a do AG padrão. Assim, a abordagem proposta é viável e eficaz na otimização das operações de sistemas de reservatórios complexos.

Bebert (2012) emprega os métodos de algoritmos genéticos e de evolução diferencial no planejamento hidroelétrico de subsistemas do sistema elétrico brasileiro. No seu trabalho de doutorado, a autora propõe quatro abordagens para a resolução do problema, baseadas em duas Metaheurísticas Evolutivas: Algoritmos Genéticos e Evolução Diferencial, considerando as análises mono-objetivo e multiobjetivo. Os algoritmos propostos foram aplicados em vários testes com usinas pertencentes ao Sistema Hidroelétrico Brasileiro. Os resultados obtidos indicam que as abordagens propostas podem ser efetivamente aplicadas ao problema de Planejamento Hidroelétrico, fornecendo soluções alternativas e eficientes. Em suas considerações finais, a autora coloca que poucos trabalhos na literatura abordam problemas multiobjetivo em espaços de busca fortemente restritos. Entretanto, este é o caso da maioria dos problemas e aplicações do mundo real, sendo, portanto, necessário o estudo e desenvolvimento de metodologias que lidem com este tipo de problema com eficiência.

Chang *et al.* (2013) propuseram um algoritmo com hibridização entre algoritmo genético e enxame de partículas, aproveitando as características positivas de ambos os métodos na aplicação para o problema de otimização de múltiplos reservatórios. É mostrada uma

comparação entre o desempenho de cada método em separado frente a metodologia proposta aplicada a um sistema de reservatórios na China. O desempenho do método híbrido mostrou-se superior a ambos os métodos em separado.

A revisão bibliográfica realizada revela que, embora muito tenha sido desenvolvido na área de otimização da operação de reservatórios e do planejamento hidroelétrico empregando algoritmos genéticos para suprirem as deficiências apresentadas ligadas à perda de diversidade, à convergência prematura e ao tratamento de múltiplas restrições, todas as alternativas apresentadas propõem alterações no método, principalmente por intermédio de hibridização.

O presente trabalho apresenta uma abordagem diferenciada. Por meio da manipulação das equações da conservação da massa e da vazão afluente aos reservatórios, introduz-se uma nova variável de decisão para o modelo, a fração de volume disponível nos reservatórios. Desta forma o problema é transformado em irrestrito e limitado, permitindo o emprego algoritmos genéticos puros, sem hibridização e sem a necessidade do tratamento de restrições.

3 *Otimização Multiobjetivo e Métodos de Solução.*

Neste capítulo será apresentado o problema da otimização multiobjetivo, bem como os métodos que podem ser utilizados para a sua análise, no intuito de encontrar um conjunto de soluções não dominadas com a maior diversidade possível, tanto no espaço de parâmetros quanto no de objetivos. Também será apresentado e discutido o método adotado para o desenvolvimento desta pesquisa .

3.1 Definição do Problema de Otimização Multiobjetivo

Num problema de otimização multiobjetivo estão envolvidas várias funções objetivo, sendo que algumas devem ser maximizadas e/ou outras minimizadas. Da mesma forma que na otimização mono-objetivo, o problema pode estar sujeito a um conjunto de restrições, ao qual todas as soluções devem satisfazer. A forma geral de um problema de otimização multiobjetivo é dada pela Equação 3.1 (DEB, 2001):

$$\begin{aligned}
 & \text{minimizar/maximizar} \quad f_m(\vec{x}) & m = 1, \dots, N_{obj} & \quad (3.1) \\
 & \text{sujeito a:} \\
 & \quad g_j(\vec{x}) \leq 0 & j = 1, \dots, J \\
 & \quad h_k(\vec{x}) = 0 & k = 1, \dots, K \\
 & \quad x_i^{(L)} \leq x_i \leq x_i^{(U)} & i = 1 \dots N_{var}
 \end{aligned}$$

onde $\vec{x} \in \Re^{N_{var}}$ é um vetor com N_{var} variáveis de decisão: $\vec{x} = (x_1, \dots, x_{N_{var}})^T$, também chamado de uma solução. Os valores $x_i^{(L)}$ e $x_i^{(U)}$ constituem os limites inferior e superior para cada variável de decisão x_i , definindo o conjunto de variáveis de decisão, ou região

de busca $\mathcal{X}$. As j desigualdades g_j e as k igualdades h_k são denominadas restrições do problema. Toda solução factível deve satisfazer as $j + k$ restrições e aos $2N_{var}$ limites das variáveis de decisão. O conjunto de todas as soluções factíveis constitui a região factível $\mathcal{F}_x$.

Na formulação apresentada na Eq. 3.1 são consideradas N_{obj} funções objetivo, sendo o vetor de funções objetivo $\vec{f} \in \mathbb{R}^{N_{obj}}$ ou $\vec{f}(\vec{x}) = (f_1(\vec{x}), \dots, f_{N_{obj}}(\vec{x}))^T$, que definem um espaço vetorial $\mathcal{Y}$, denominado espaço de objetivos. Entre as funções objetivo envolvidas no modelo matemático, algumas podem ser maximizadas e outras minimizadas. Em geral, os algoritmos de otimização tratam apenas da minimização de funções, convertendo um problema de maximização em um de minimização, simplesmente multiplicando a função objetivo por -1 .

Diferentemente da otimização mono-objetivo, onde a função objetivo é escalar, na otimização multiobjetivo ocorre um mapeamento de cada solução $\vec{x}$ no espaço de variáveis de decisão, em um ponto no espaço vetorial de objetivos. Esse mapeamento leva um vetor N_{var} -dimensional em outro vetor N_{obj} -dimensional.

O propósito da otimização multiobjetivo é determinar um conjunto de soluções, denominado conjunto de Pareto ou conjunto Pareto-ótimo, que representa as soluções do problema (3.1). Este conceito foi elaborado por Vilfredo Pareto em 1896, que enunciou a relação Pareto-Ótima que diz: “não é possível melhorar uma característica do problema sem piorar outra”, o que caracteriza a relação conflitante entre os objetivos na otimização multiobjetivo.

A seguir, apresentam-se algumas definições e conceitos para a melhor compreensão do conjunto Pareto-ótimo.

Definição 1 : Dominância:

Para definir o conceito de dominância, será utilizada a seguinte notação para comparação de vetores no espaço $\mathbb{R}^{N_{obj}}$:

$$\begin{aligned} \vec{f}(\vec{x}) \leq \vec{f}(\vec{y}) &\Rightarrow \{f_m(\vec{x}) \leq f_m(\vec{y}) \quad , \quad \forall m \in \{1, 2, \dots, N_{obj}\} \\ \vec{f}(\vec{x}) \neq \vec{f}(\vec{y}) &\Rightarrow \quad \{\exists m \mid f_m(\vec{x}) \neq f_m(\vec{y})\} \end{aligned} \quad (3.2)$$

Sejam $\vec{x}_1$ e $\vec{x}_2$ dois pontos do espaço de parâmetros. Diz-se que o ponto $\vec{x}_1$ domina o ponto $\vec{x}_2$, $\vec{x}_1 \prec \vec{x}_2$ se ambas as condições se verificarem:

- i. A solução $\vec{x}_1$ não é pior do que $\vec{x}_2$ para nenhum objetivo, ou seja, $f_m(\vec{x}_1) \leq f_m(\vec{x}_2)$ para $m = 1, \dots, N_{obj}$.
- ii. A solução $\vec{x}_1$ é estritamente melhor que a solução $\vec{x}_2$ em pelo menos um objetivo, ou seja, existe $m \in \{1, \dots, N_{obj}\} \mid f_m(\vec{x}_1) < f_m(\vec{x}_2)$.

O conceito da dominância, para minimização de duas funções objetivo, encontra-se ilustrado na Figura 2, onde são mostrados os pontos y_A a y_F pertencentes ao espaço de objetivos $\mathcal{Y}$. Cones de dominância paralelos aos eixos coordenados são colocados em cada um desses pontos. Todos os pontos localizados no interior de qualquer um dos cones são dominados pelo ponto que se localiza no seu vértice, de forma que: (i) entre y_A, y_B e y_E não há relação de dominância; (ii) y_A domina y_C e y_F ; (iii) y_B domina y_C, y_D e y_F ; (iv) entre y_C, y_D e y_E não há relação de dominância; (v) y_C e y_D dominam y_F ; (vi) y_E e y_F não dominam nenhum ponto mostrado.

Se alguma das condições for violada, então $\vec{x}_1$ não domina a solução $\vec{x}_2$, o que não implica em $\vec{x}_2$ dominar $\vec{x}_1$. Na verificação da relação de dominância podem ocorrer:

- $\vec{x}_1$ domina $\vec{x}_2$;
- $\vec{x}_2$ domina $\vec{x}_1$; e
- não existe relação de dominância entre as soluções $\vec{x}_1$ e $\vec{x}_2$.

Para um conjunto finito de soluções, é possível compará-las par a par e determinar aquelas que dominam, aquelas que são dominadas e quais são as soluções não dominadas. Ao final da otimização espera-se encontrar um conjunto de soluções que não se dominam. Além disso, este conjunto deve dominar todas as soluções que não pertençam a ele (CRUZ, 2011). Este conjunto de soluções não-dominadas é definido como Conjunto Pareto-ótimo.

Definição 2 : Conjunto Pareto-ótimo:

Seja $\mathcal{P}$ um conjunto de soluções. O conjunto de soluções não-dominadas $\mathcal{P}'$, ou Conjunto Pareto-ótimo, é composto por aquelas soluções que não são dominadas por nenhum outro elemento do conjunto $\mathcal{P}$.

Da mesma forma que na otimização mono-objetivo, onde existem ótimos globais e locais, na otimização multiobjetivo tem-se soluções Pareto-ótimas locais e globais, definidas a seguir.




FIGURA 2: Representação gráfica da relação de dominância entre soluções, são mostrados os pontos y_A a y_F pertencentes ao espaço de objetivos Y , onde os pontos y_A , y_B e y_E são os pontos não dominados deste conjunto de soluções.

Definição 3 : Conjunto Pareto-ótimo Global

O conjunto não-dominado de toda a região factível $\mathcal{F}_x$ é o conjunto Pareto-ótimo Global $\mathcal{X}^*$. Ou seja, $\vec{x} \in \mathcal{X}^* \subset \mathcal{F}_x$ é uma solução Pareto-ótima Global, se não existir outra solução $\vec{x} \in \mathcal{F}_x$ tal que $f_m(\vec{x}) \leq f_m(\vec{x}^*)$ para todo $m = 1, \dots, N_{obj}$ e $\vec{f}(\vec{x}) \neq \vec{f}(\vec{x}^*)$.

Em geral, faz-se referência ao conjunto Pareto-ótimo Global $\mathcal{X}^*$ como conjunto Pareto-ótimo, uma vez que as soluções componentes deste conjunto não são dominadas por nenhum outro ponto da região factível. A Imagem do conjunto $\mathcal{X}^*$ no espaço dos objetivos define a Fronteira de Pareto $\mathcal{Y}^*$.

Definição 4 : Conjunto Pareto-ótimo local:

Seja $\vec{x}$ um ponto factível do espaço de parâmetros, $\vec{x} \in \mathcal{F}_x$. Diz-se que $\vec{x}$ é uma solução Pareto-ótima local do problema multiobjetivo numa dada vizinhança, se existe $\epsilon > 0$ tal que não exista $\vec{y} \in \mathcal{F}_x$ com $\|\vec{x} - \vec{y}\| < \epsilon$, de modo que $f_m(\vec{y}) \leq f_m(\vec{x})$ para todo $m = 1, \dots, M$ e $\vec{f}(\vec{y}) \neq \vec{f}(\vec{x})$.

Definição 5 : Solução Utópica: *A solução utópica do problema multiobjetivo é definida como:*

$$y_{*i} = f_i(\vec{x}^{(i)}) \quad , \quad i = 1, \dots, N_{obj}$$

onde:

$$\vec{x}^{(i)} = \arg \min_{\vec{x} \in \mathcal{F}_x} f_i(\vec{x}).$$

A solução utópica y_* é uma escolha conveniente para localização da origem do espaço dos objetivos $\mathcal{Y}$, uma vez que tal escolha deixa toda a fronteira de Pareto no primeiro quadrante, com interseções com os eixos coordenados correspondentes aos mínimos individuais de cada uma das funções objetivo do problema (TAKAHASHI, 2007).

Ao contrário da ideia da solução utópica, que representa o limite inferior de cada função no espaço de objetivos, a *Solução de Nadir* representa o limite superior de cada função sobre todo o conjunto Pareto-ótimo (CRUZ, 2011).

Verifica-se, então, que no contexto da otimização multiobjetivo não é mais possível escolher simplesmente uma única solução ótima considerando apenas um único objetivo, quando o restante dos objetivos é também importante. O conjunto de soluções não dominadas representam relações de *trade-offs* entre os objetivos, assim uma solução que é

extrema para um objetivo representa um prejuízo para os outros objetivos. Este fato proíbe a escolha de uma solução que é ótima com relação a um único objetivo sem avaliar o prejuízo nos outros.

Baseando-se neste comportamento, duas metas são apresentadas para a análise multiobjetivo (DEB, 2011):

- Encontrar o conjunto de soluções não dominadas que definem a fronteira Pareto-ótima, ou uma aproximação suficiente desta fronteira; e
- Encontrar o conjunto de soluções não dominadas que seja diversificado o suficiente para representar o intervalo inteiro coberto pela fronteira Pareto-ótima.

3.2 Métodos de Solução para Otimização Multiobjetivo

Considerando que o resultado da análise de um problema multiobjetivo é um conjunto de soluções não comparáveis entre si, faz-se necessária a utilização de critérios para a opção por uma única solução final, que represente a relação de compromisso ideal entre os objetivos conflitantes do problema. Estes critérios para a tomada de decisão são fornecidos pelo decisor.

Segundo (HORN, 1997), na solução de problemas multiobjetivo, duas etapas distintas podem ser identificadas: a busca de soluções e a tomada de decisão. A primeira se refere ao processo de otimização, em que o conjunto de soluções viáveis, ou factíveis, deve ser guiado em direção ao conjunto de soluções Pareto-ótimas. A segunda, a tomada de decisão, consiste na seleção de um critério apropriado para a escolha de uma solução do conjunto Pareto-ótimo. Este critério será utilizado pelo decisor para a tomada de decisão, ou seja, ele poderá ponderar entre as diferentes soluções eficientes conflitantes.

De acordo com o momento, no processo de solução, em que é feita a interferência do decisor, os métodos de solução podem ser classificados em (HORN, 1997; ZITZLER, 1999):

- Métodos *a priori* ou de decisão antes da otimização: os objetivos do problema são agregados num objetivo incluindo implicitamente a preferência do decisor;
- Métodos *a posteriori* ou de decisão pós-otimização: a otimização é realizada sem a interferência do decisor;

- Métodos iterativos ou de decisão durante a otimização: o decisor interfere durante o processo de otimização guiando a busca para regiões com soluções de seu interesse.

Muitos métodos, tanto determinísticos quanto estocásticos, têm sido propostos para a obtenção do conjunto de soluções eficientes para a otimização multiobjetivo. Estes são classificados em dois grupos fundamentais: Métodos Clássicos e Métodos Heurísticos ou Estocásticos.

3.2.1 Métodos de Solução Clássicos

Nesta classe se incluem todos os métodos que buscam encontrar o conjunto Pareto-ótimo de um problema multiobjetivo por meio de uma transformação para um problema mono-objetivo.

A agregação de múltiplos objetivos em um único apresenta como vantagem a possibilidade de aplicar qualquer técnica clássica de otimização escalar sem importantes modificações. Contudo, apresenta como grande desvantagem a determinação de uma única solução a cada execução do algoritmo (ZITZLER, 1999).

Os métodos clássicos para geração do conjunto Pareto-ótimo trabalham de forma similar à função objetivo parametrizada dos métodos de otimização *a priori*. Entretanto, os parâmetros que combinam linearmente os objetivos numa única função não são estabelecidos pelo decisor, como nos métodos *a priori*, mas variados sistematicamente pelo otimizador.

Diversas execuções do algoritmo de otimização, para diferentes valores de parâmetros, são realizadas para alcançar um conjunto de soluções Pareto-ótimo aproximadas (ZITZLER, 1999).

Pertencem a esta classe de métodos o Método da Soma Ponderada, o Método ϵ -Restrito e o Método de Programação por Metas. O método da soma ponderada é apresentado a seguir, tanto por ter sido por muito tempo amplamente empregado quanto porque a análise de suas limitações contribui para a compreensão dos problemas encontrados na otimização multiobjetivo. Também se apresenta o método ϵ -Restrito, aqui utilizado no tratamento de um terceiro objetivo no item 6.3.2.

i. Método da Soma Ponderada

Neste método o problema original de múltiplos objetivos é transformando num problema de objetivo único, por intermédio de uma combinação linear dos objetivos

originais:

$$\begin{aligned} \text{minimizar} \quad & f(\vec{x}) = \sum_{i=1}^r w_i \cdot f_i(\vec{x}) \\ \text{sujeito a:} \quad & \vec{x} \in \mathcal{F}_x \end{aligned} \tag{3.3}$$

onde w_i são os pesos de cada objetivo e que, sem perda de generalidade, são normalizados tal que $\sum w_i = 1$. Resolvendo-se o problema de otimização escalar acima para vários valores de pesos, tem-se um conjunto de soluções (ZITZLER, 1999).

A grande desvantagem desta metodologia é que não se consegue gerar todas as soluções Pareto-ótimas em problemas com espaços de objetivos não-convexos. Uma representação de pontos que não seriam obtidos, para o caso de dois objetivos, é mostrada na Figura 3. Em geral, nem todos os pontos do espaço de objetivos admitem retas suporte como os representados na figura pelos pontos C e D. Assim, estes dois pontos não poderiam ser determinados pelo método aqui descrito. Considere os pesos w_1 e w_2 pesos fixos que minimizam a seguinte função:

$$y = w_1 \cdot f_1(\vec{x}) + w_2 \cdot f_2(\vec{x})$$

Esta equação pode ser reescrita como:

$$f_2(\vec{x}) = -\frac{w_1}{w_2} \cdot f_1(\vec{x}) + \frac{y}{w_2}$$

que define uma reta com declividade $-\frac{w_1}{w_2}$ e que intercepta o eixo vertical no ponto $\frac{y}{w_2}$. Esta reta constitui a reta suporte ao espaço factível de objetivos $\mathcal{F}_y$, num ponto Pareto-ótimo. Assim, graficamente, o método da soma ponderada consiste em gerar diferentes retas suporte, definidas pela inclinação $-\frac{w_1}{w_2}$.

ii. método ε -restrito:

Este método consiste em transformar $N_{obj} - 1$ funções objetivo em restrições e otimizar o objetivo restante, que pode ser escolhido arbitrariamente (ZITZLER, 1999), transformando o problema original de otimização vetorial em um de otimização




FIGURA 3: Interpretação gráfica do método da soma ponderada (ZITZLER, 1999; ARROYO, 2002).

escalar, assim formulado:

$$\begin{aligned}
 & \text{minimizar} && f_1(\vec{x}) \\
 & \text{sujeito a:} && f_i(\vec{x}) \leq \varepsilon_i, i = \{2, \dots, N_{obj}\} \\
 & && \vec{x} \in \mathcal{F}_x
 \end{aligned} \tag{3.4}$$

onde ε_i são as limitantes superiores para os objetivos f_i , que serão variadas pelo otimizador com o objetivo de encontrar múltiplas soluções Pareto-ótimas.

A Figura 4 mostra que, para um problema com dois objetivos, o método ε -restrito tem capacidade de obter soluções associadas com partes não-convexas da frente de Pareto. É mostrado também que para um valor de $\varepsilon_2 = K$, os pontos A, B, C, D e G representam soluções factíveis, enquanto que os pontos E e F representam duas soluções infactíveis. E ainda, que para um valor de $\varepsilon_2 = K'$, o método obteria um conjunto vazio de soluções factíveis, isto é, nenhuma solução corresponderia ao problema de otimização escalar dado pela Equação (3.4). Para evitar esta situação, os valores das restrições ε devem ser gerados com valores apropriados.




FIGURA 4: Interpretação gráfica do método ε -restrito adaptado de (ARROYO, 2002).

Abordagens de escalarização paramétrica, como as mostradas no item anterior (Soma Ponderada, ϵ -restrito entre outras), convertem um problema de otimização vetorial em um de otimização escalar parametrizado, que é resolvido várias vezes, variando-se a cada execução os parâmetros (vetor de pesos ou de restrições) (DEB, 2011). Outro fator limitador do emprego das técnicas clássicas é o fato de que uma distribuição uniforme nos parâmetros não garante a diversidade das soluções eficientes encontradas (AMORIM, 2006).

3.2.2 Métodos de Solução Evolutivos

Algoritmos Evolutivos ou Evolucionários (AEs) são métodos de busca heurísticos inspirados em analogias com a evolução natural. Em seus estudos, o naturalista inglês Charles Darwin define Seleção Natural como a preservação dos indivíduos mais adaptados ao ambiente, tendo eles maiores chances de competirem, se reproduzirem e sobreviverem na natureza, implicando numa evolução natural, em que os menos adaptados tenderiam a desaparecer (DARWIN, 1868).

Estudos posteriores mostram que estas características seriam determinadas por pequenas unidades denominadas *genes* que, por sua vez, formam um conjunto denominado *cromossoma*. Com o passar das gerações, não somente os indivíduos mais adaptados sobreviveriam, como também os genes que representam suas melhores características seriam transmitidos aos descendentes através do processo de reprodução sexuada.

Os Algoritmos Evolutivos representam a abstração dos processos envolvidos na biologia evolutiva (CASTRO, 2007). Os AE's trabalham com uma *população de indivíduos* (conjunto de possíveis soluções para o problema) capazes de se reproduzirem, sujeitos à variação genética e submetidos a seleção, resultando em novas populações de indivíduos cada vez mais adaptados ao ambiente. Então, a ideia básica da computação evolutiva é empregar uma analogia com os processos da evolução natural como paradigma no desenvolvimento de técnicas de busca e otimização. Estas operações são realizadas iterativamente, onde cada iteração é denominada geração.

A despeito de algumas diferenças, todos os algoritmos evolutivos apresentam como características básicas (CASTRO, 2007):

- **uma população de indivíduos que se reproduzem com herança genética:** cada indivíduo da população representa uma possível solução para o problema em estudo. Os indivíduos podem se reproduzir, de forma sexuada ou assexuada, gerando

filhos que herdaram características dos pais.

- **variação genética:** os filhos gerados estão sujeitos à variação genética por meio do operador de mutação, que permite que os filhos apresentem traços não herdados dos pais, explorando, assim, outras regiões do espaço de busca.
- **seleção natural:** a avaliação do desempenho dos indivíduos em seu ambiente é medida a partir de um valor de aptidão (ou *fitness*) para cada indivíduo. A seleção para sobrevivência e reprodução é feita a partir da comparação destes valores de aptidão.

Os algoritmos evolutivos, via de regra, não são tão eficientes e precisos quanto os algoritmos determinísticos, nos casos em que estes podem ser aplicados. Entretanto, há diversas classes de problemas de interesse para a engenharia e de outras áreas em que não podem ser aplicados métodos determinísticos. Citam-se aqui por exemplo, problemas em que as funções objetivo ou de restrições sejam descontínuas, não diferenciáveis, multimodais ou de múltiplas escalas: os algoritmos evolucionários são naturalmente adequados para trabalharem com problemas com tais características. Os AEs são classificados como métodos de otimização global e são métodos robustos e efetivos para encontrar pontos de ótimo global aproximados.

Os AEs não utilizam informações como derivadas das funções objetivo ou de restrição durante o processo de busca, o que implica numa taxa de convergência mais lenta, se comparados às técnicas clássicas de busca local. A natureza exploratória dos AEs conduz a uma identificação rápida das regiões promissoras no espaço de busca. Embora possam parecer simplistas do ponto de vista biológico, os AEs são suficientemente complexos para fornecer mecanismos de busca adaptativos, eficientes e robustos. Knowles *et al.* (2007) apontam como incentivo à aplicação dos AEs: desempenho e eficiência (em alguns problemas os AEs encontram soluções melhores, competitivas ou em melhores tempos computacionais que outros métodos conhecidos), aplicabilidade e acessibilidade (os AEs são aplicáveis a uma grande variedade de problemas de otimização) e favorabilidade (para algumas aplicações os AEs são a única abordagem possível).

Cabe citar, em particular, a aplicabilidade dos AEs em problemas de otimização multiobjetivo. Como esses algoritmos trabalham com a evolução de um conjunto de soluções tentativas, eles são capazes de produzir em cada execução diversos pontos do conjunto de soluções Pareto-ótimas.

A principal diferença dos algoritmos evolutivos em relação aos métodos clássicos é

que múltiplas soluções do conjunto Pareto-ótimo podem ser encontradas em uma única execução do código, enquanto que a maioria dos métodos clássicos irão requerer múltiplas execuções. Além desta significativa diferença, os métodos clássicos devem superar a cada execução as dificuldades relacionadas com regiões infactíveis, ótimos locais, regiões onde a função objetivo não varia ou pouco varia, etc, para convergir para o ótimo local daquela execução. Dado que as execuções são independentes, nenhuma informação sobre o sucesso ou falha das execuções anteriores é utilizada para acelerar o processo de encontrar o conjunto de soluções não-dominadas (DEB, 2011).

Em problemas multiobjetivo com características mais complexas, esta falta da informação de execuções anteriores pode implicar num tempo computacional excessivo para obter o conjunto de Pareto. Por outro lado, embora a convergência seja alcançada em alguns problemas usando simulações independentes, não há garantia de que o conjunto obtido apresente uma boa distribuição, ou seja, podem não ser representativas para todo intervalo coberto pela frente de Pareto obtida.

Autores como Deb (2009), Simonovic (2009), Coello *et al.* (2007) indicam algumas vantagens dos algoritmos evolucionários sobre os métodos clássicos, entre elas citam-se:

- utilizam uma população de soluções, de forma evolutiva, operando sobre um ou mais membros desta população, com o intuito de obter várias soluções não dominadas em uma única execução;
- a flexibilidade desses métodos em relação as funções objetivo e de restrições;
- não exigem conhecimento profundo de modelos de otimização linear;
- em geral são de fácil implementação;
- são menos suscetíveis ao formato e continuidade da frente de Pareto;
- não dependem de informações adicionais como derivadas das funções objetivo ou de restrições;
- não dependem da solução inicial como ocorre com muitos métodos determinísticos.

3.3 Algoritmos Genéticos

Na classe dos AEs se enquadram os Algoritmos Genéticos (AGs). Os AGs são métodos de busca estocástica que imitam matematicamente os mecanismos da evolução natural das

espécies. São métodos flexíveis com capacidade de produzir boas soluções em problemas complexos e de grande porte, o que favorece sua aplicação, de forma exitosa, em diferentes áreas, tais como: economia, logística, petróleo e gás, aerodinâmica, telecomunicações, entre outras.

Os AGs foram introduzidos por J. H. Holland, na década de sessenta, e refinados por ele e colaboradores na década seguinte na Universidade de Michigan, nos Estados Unidos. Como métodos computacionais de otimização, estes algoritmos empregam uma estratégia de busca paralela (numa população de soluções candidatas), estruturada, porém aleatória, com objetivo de alcançar novos pontos com alta aptidão, isto é, pontos que apresentam melhores valores da função objetivo.

Em geral os AGs apresentam as seguintes características(GOLDBERG, 1989):

- trabalham com uma população e não com um único ponto;
- operam num espaço de busca codificado;
- necessitam somente da informação das funções objetivo e restrições para cada indivíduo da população, prescindindo do conhecimento de derivadas ou outras informações auxiliares;
- empregam regras de transição probabilísticas e não determinísticas para o avanço da solução.

Apesar de aleatórios, os AGs realizam uma busca direcionada, pois utilizam valores históricos das funções para encontrar novas soluções. Um conjunto de operações é necessário para evoluir populações sucessivas com desempenho melhor do que as anteriores. A existência de três regras básicas, ou operadores genéticos básicos, define um algoritmo genético (GOLDBERG, 1989):

- i. Um operador de *cruzamento* que gera novos indivíduos mediante a combinação de informações de dois ou mais indivíduos (herança). O cruzamento é considerado o operador genético predominante, por ser aplicado com probabilidades muito maiores do que a mutação;
- ii. Um operador de *mutação* que, a partir da informação contida num indivíduo, gera estocasticamente um novo indivíduo. A mutação mantém a diversidade genética da população;

- iii. Um operador de *seleção* que, utilizando a avaliação da função objetivo de todos os indivíduos da população, produz réplicas de alguns (mais adaptados) e elimina outros indivíduos, criando assim a nova população.

Além desses operadores, os AGs podem envolver outros operadores como de: *busca local*, *nicho*, *dizimação*, etc.

Outro aspecto a ser considerado na utilização de AGs é a codificação das variáveis de decisão. Estas podem ser binária, real, inteira e outras. Tratando-se de problemas com variáveis reais, a codificação real é a mais simplificada e imediata, o que justifica a sua utilização neste trabalho.

3.4 Algoritmo Evolutivo Multiobjetivo NSGA II

O presente trabalho utiliza como base o algoritmo *Non-Dominated Sorting Genetic Algorithm II* (NSGA-II), proposto por Deb *et al.* (2002), versão aprimorada daquela proposta por Srinivas e Deb (1994), em razão de limitações existentes, tais como: falta de elitismo e a necessidade de especificar um valor para o parâmetro de *sharing*. Para solucionar os problemas apresentados nesta versão do algoritmo foram introduzidas três inovações: o *Fast Nondominated Sorting* (procedimento rápido para ordenação por não dominância), o *Crowding Distance* (medida da aglomeração das soluções) e o operador *Crowding Comparison* (operador de comparação de aglomeração).

No bloco principal do NSGA-II (Algoritmo 1), inicialmente é criada uma população P_1 aleatória de pais de tamanho N_{ind} indivíduos. Essa população inicial é ordenada pela não-dominância por intermédio do *Fast Nondominated Sorting* (Algoritmo 2), obtendo-se as l primeiras fronteiras $\mathcal{F}^{(1)} = (\mathcal{F}_1, \mathcal{F}_2, \dots, \mathcal{F}_l)$ da primeira geração, com l camadas. A cada solução da população é atribuída um valor de adequabilidade (*fitness* ou *rank*) igual ao nível da fronteira de não-dominância (1 é o melhor nível, 2 é o segundo melhor e assim por diante). Para estimar a densidade de soluções em torno de uma determinada solução é calculada a distância média de duas outras soluções, uma em cada lado da solução em questão, para cada objetivo. Um valor de distância igual a diferença normalizada dos valores da função objetivo de duas soluções adjacentes é associado ao *Crowding Distance-CD*, como implementado pelo Algoritmo 3.

Para cada geração g das N_{iter} gerações são aplicados os operadores de seleção por torneio binário, cruzamento e mutação para criar uma população de filhos Q_g com N_{ind} indivíduos. O elitismo é introduzido comparando a população de $2N_{ind}$ indivíduos dos

pais e filhos, R_g , para se extrair as N_{ind} melhores soluções para formar a próxima população P_{g+1} de pais da próxima geração. A extração dos N_{ind} indivíduos é mostrada pelo Algoritmo 4 que executa os seguintes passos (CRUZ, 2011):

- Ordena-se R_g pela não-dominância classificando as soluções em novas fronteiras $\mathcal{F}^{(g)} = (\mathcal{F}_1, \dots, \mathcal{F}_l)$ da primeira geração, com l camadas;
- Deve-se extrair as N_{ind} melhores soluções, das $2N_{ind}$ de R_g , para se tornar a próxima população de pais P_{g+1} . Deve-se incluir todas as soluções das primeiras fronteiras por completo em P_{g+1} até não exceder N_{ind} soluções. Se por acaso a j -ésima fronteira for a última que deve ser incluída por completo, não preenchendo P_{g+1} com N_{ind} soluções, e se a inclusão do total de soluções da $(j+1)$ -ésima fronteira exceder N_{ind} , então:
 - Deve-se ordenar, em ordem crescente, as soluções da $(j+1)$ -ésima fronteira pelo operador de *Crowded-Comparison Operator* ($\prec_n$) (Definição 6) e finalmente;
 - Inserir as primeiras soluções ordenadas da $(j+1)$ -ésima fronteira até completar N_{ind} indivíduos em P_{g+1} .

O algoritmo NSGA-II evolui até que um critério de parada seja alcançado, geralmente um número máximo de gerações N_{iter} . As soluções finais encontram-se em $\mathcal{P}_{t+1} \cup \mathcal{Q}_{t+1}$. A sequência seguida pelo NSGA-II é apresentada pela Figura 5.

Algorithm 1 NSGA-II

```

 $P_1 \leftarrow InitialPopulation()$ 
 $P_1 \leftarrow EvaluatePopulation(P_1)$ 
 $\mathcal{F}^{(1)} \leftarrow FastNonDominatedSorting(P_1)$ 
 $\mathcal{F}^{(1)} \leftarrow CrowdingDistance(\mathcal{F}^{(1)})$ 
for  $g$  from 1 to  $N_{iter}$  step 1 do
   $Q_g \leftarrow SelectionAndRecombination(P_g)$ 
   $Q_g \leftarrow Mutation(Q_g)$ 
   $Q_g \leftarrow EvaluatePopulation(Q_g)$ 
   $R_g \leftarrow P_g \cup Q_g$ 
   $\mathcal{F}^{(g)} \leftarrow FastNonDominatedSorting(R_g)$ 
   $P_{g+1} \leftarrow FillNondominated(R_g, \mathcal{F}^{(g)})$ 
end for

```

Os principais procedimentos do NSGA-II são descritos a seguir:

Procedimento rápido para ordenação das soluções pela não dominância (*Fast Non-Dominated Sorting Procedure*): classifica os indivíduos pelo nível da fronteira




FIGURA 5: Funcionamento geral do NSGA-II (adaptado de (DEB *et al.*, 2002)).

de Pareto de acordo com a relação de dominância. Por exemplo, os que não são dominados por nenhuma outra solução recebem o índice de fronteira 1, os que são dominados somente pelas soluções que pertencem a fronteira 1 recebem o índice 2, aqueles que são dominados somente pelas soluções das fronteiras 1 e 2 recebem o índice 3. Essa operação se repete até que não haja mais indivíduos para serem classificados com relação a dominância.

O Algoritmo 2 apresenta o pseudocódigo desse procedimento, com ordem de complexidade $\mathcal{O}(M\Pi^2)$ (DEB *et al.*, 2002), onde M é o número de objetivos e Π é o número de indivíduos na população. Esta atribuição é feita da seguinte forma:

- Para cada solução p pertencente a população P determina-se o contador de dominância n_p (o número de soluções que dominam a solução p) e o conjunto S_p (conjunto de soluções que a solução p domina);
- A primeira fronteira a ser classificada será indexada por $i = 1$;
- Serão classificadas pertencentes à i -ésima fronteira $\mathcal{F}_i$, todas as soluções que apresentarem $n_p = 0$;
- Enquanto houver soluções não classificadas, é feito:
 - Para toda solução $p \in \mathcal{F}_i$ e toda solução $q \in S_p$, faz-se $n_q \leftarrow n_q + 1$, sendo removida desta forma a informação da contagem de dominância da fronteira i ;
 - A próxima fronteira a ser classificada é indexada por $i + 1$;
 - Todas as soluções que apresentarem contador de dominância $n_q = 0$, serão classificadas como pertencentes a i -ésima fronteira não dominada $\mathcal{F}_i$.

Algorithm 2 FastNonDominatedSorting(P)

```

for all  $p \in P$  do
   $S_p \leftarrow \emptyset$ 
   $n_p \leftarrow 0$ 
  for all  $q \in P$  do
    if  $p \prec q$  then
       $S_p \leftarrow S_p \cup \{q\}$ 
    else if  $q \prec p$  then
       $n_p \leftarrow n_p + 1$ 
    end if
  end for
  if  $n_p = 0$  then
     $p_{\text{rank}} \leftarrow 1$ 
     $\mathcal{F}_1 \leftarrow \mathcal{F}_1 \cup \{p\}$ 
  end if
end for
 $i \leftarrow 1$ 
while  $\mathcal{F}_i \neq \emptyset$  do
   $Q \leftarrow \emptyset$ 
  for all  $p \in \mathcal{F}_i$  do
    for all  $q \in S_p$  do
       $n_q \leftarrow n_q - 1$ 
      if  $n_q = 0$  then
         $q_{\text{rank}} \leftarrow i + 1$ 
         $Q \leftarrow Q \cup \{q\}$ 
      end if
    end for
  end for
   $i \leftarrow i + 1$ 
   $\mathcal{F}_i \leftarrow Q$ 
end while

```

Elitismo: O elitismo é introduzido armazenando as melhores soluções e introduzindo na geração da próxima população do AG, o que é feito utilizando uma metodologia de preservação em todas as gerações, aprimorando a convergência na obtenção do conjunto Pareto Ótimo;

Preservação de Diversidade das Soluções (*Crowding Distance-CD*): Para a preservação da diversidade da população no NSGA-II é empregada uma medida de aglomeração ou estimativa da densidade das soluções que rodeiam cada indivíduo da população. Para isso, calcula-se a distância entre duas soluções adjacentes a cada indivíduo para todos os objetivos das soluções numa fronteira. Esta distância $\mathcal{I}[i]_{distance}$ (*Crowding Distance*) corresponde ao perímetro do cuboide cujos vértices estão alocados nas duas soluções mais próximas na mesma fronteira, como é apresentado na Figura 6.

A determinação da medida de aglomeração requer o ordenamento, em ordem crescente, da população de acordo com o valor de cada função objetivo. Para os extremos de cada função objetivo (soluções com o maior e menor valor da função objetivo) é atribuído um valor de distância de aglomeração infinito ($\mathcal{I}[1] = \mathcal{I}[|\mathcal{I}|] = \infty$), pois elas deverão ser preservadas para a próxima geração. Para todas as outras soluções intermediárias é atribuída a distância igual ao valor absoluto da diferença normalizada dos valores de função das duas soluções adjacentes. O mesmo cálculo é feito para todas as outras funções objetivo. O valor total da distância de aglomeração é a soma dos valores individuais das distâncias para cada objetivo.




FIGURA 6: Cálculo da crowding distance no espaço bidimensional de objetivos. Os pontos preenchidos são soluções da mesma fronteira não dominada.

O Algoritmo 3 apresenta o procedimento de cálculo da distância de aglomeração para todas as soluções de um conjunto não dominado $\mathcal{I}$, onde: $\mathcal{I}[i].m$ refere-se ao valor m -ésima função objetivo do i -ésimo indivíduo do conjunto $\mathcal{I}$ e $f_m^{\max}$ e $f_m^{\min}$ são os valores máximos e mínimos obtidos para a m -ésima função objetivo.

Algorithm 3 CrowdingDistance($\mathcal{I}$)

```

size  $\leftarrow |\mathcal{I}|$ 
for all  $i \in \mathcal{I}$  do
     $\mathcal{I}[i]_{\text{distance}} \leftarrow 0$ 
end for
for all objective  $m$  do
     $\mathcal{I} \leftarrow \text{sort}(\mathcal{I}, m)$ 
     $\mathcal{I}[1]_{\text{distance}} \leftarrow \infty$ 
     $\mathcal{I}[\text{size}]_{\text{distance}} \leftarrow \infty$ 
    for  $i$  from 2 to size - 1 do
         $\mathcal{I}[i]_{\text{distance}} \leftarrow \mathcal{I}[i]_{\text{distance}} + (\mathcal{I}[i+1].m - \mathcal{I}[i-1].m) / (f_m^{\max} - f_m^{\min})$ 
    end for
end for

```

Após ser feita a atribuição da distância de aglomeração a todos os membros da população do conjunto não dominado $\mathcal{I}$, pode-se comparar duas soluções, aquela que tiver um menor valor de distância de aglomeração está mais aglomerada. No processo de seleção, quando comparadas duas soluções que estão sobre a mesma fronteira, deve ser escolhida a solução com maior distância de aglomeração para buscar diversidade e obter uma fronteira com soluções uniformemente espalhadas.

Com esta finalidade, no NSGA-II, foi incorporado um operador de comparação de aglomeração, que guia o processo de seleção durante o processamento do algoritmo na busca de uma fronteira de Pareto uniformemente espalhada.

Definição 6 : *Operador de Comparação de Aglomeração (Crowded-Comparison Operator)* Sejam i e j duas soluções das fronteiras i_{rank} e j_{rank} , com medidas de aglomeração i_{distance} e j_{distance} . O Operador de Comparação de Aglomeração ($\prec_n$) é definido como:

$$i \prec_n j \equiv (i_{\text{rank}} < j_{\text{rank}}) \text{ ou } ((i_{\text{rank}} = j_{\text{rank}}) \text{ e } (i_{\text{distance}} > j_{\text{distance}}))$$

Operadores Genéticos:

Seleção: é baseada em torneio binário de modo que dois indivíduos são selecionados aleatoriamente entre todos os indivíduos da população de acordo com os seguintes critérios para a escolha de um deles:

Algorithm 4 FillNondominated($R_g, \mathcal{F}$)

```

 $P \leftarrow \emptyset$ 
 $\mathcal{F} \leftarrow \text{FastNonDominatedSorting}(R_g)$ 
 $i = 1$ 
while  $|P| + |\mathcal{F}_i| \leq N_{ind}$  do
     $P \leftarrow P \cup \mathcal{F}_i$ 
     $i \leftarrow i + 1$ 
end while
 $\mathcal{F}_i \leftarrow \text{sort}(\mathcal{F}_i, \prec_n)$ 
 $P \leftarrow P \cup \mathcal{F}_i(1 : N_{ind} - |\mathcal{F}_i|)$ 

```

- de dois indivíduos infactíveis, ganha o menos infactível, ou seja, o que possua o menor valor da soma, em valor absoluto, das restrições violadas;
- de um indivíduo factível e outro infactível, ganha o primeiro;
- de dois indivíduos factíveis ganha aquele que está na melhor fronteira de Pareto;
- de dois indivíduos factíveis que ocuparem a mesma fronteira ganha o que tiver maior distância de aglomeração (*Crowded-Comparison Operator*);
- ainda assim, ocorrendo empate, sorteia-se um deles, com chances iguais para cada um.

O NSGA-II não utiliza parâmetros de penalidade no tratamento de restrições infringidas, como na versão anterior do algoritmo NSGA, tratando-as por meio de operações de comparação entre soluções, no momento da seleção.

O método de tratamento de restrições do NSGA-II utiliza um vetor que acumula para cada restrição infringida o valor de quanto aquele indivíduo a violou, ou zero caso não haja violação da restrição. O somatório dos valores absolutos desse vetor indica a intensidade da violação. Dessa forma, quanto maior for o valor do somatório mais infactível o indivíduo é considerado. Obviamente, se o somatório for zero então o indivíduo é factível.

Cruzamento: o NSGA-II emprega o cruzamento binário simulado, *Simulated Binary Crossover-SBX* (DEB; AGRAWAL, 1995), aplicado com uma determinada probabilidade. Dados dois indivíduos pais p_1 e p_2 , o operador de cruzamento gera dois filhos q_1 e q_2 a partir da seguinte relação:

$$q_1 = 0.5((1 + \beta)p_1 + (1 - \beta)p_2)$$

$$q_2 = 0.5((1 - \beta)p_1 + (1 + \beta)p_2)$$

em que β é um número aleatório dado pela distribuição abaixo, :

$$\beta = \begin{cases} (2u)^{\frac{1}{n_c-1}} : \text{se } u \leq 0.5 \\ \left[\frac{1}{2(1-u)} \right]^{\frac{1}{n_c-1}} : \text{se } u > 0.5 \end{cases}$$

em que u é um número aleatório entre 0 e 1 e n_c é um valor positivo que define quão próximo dos pais serão criados os indivíduos filhos.

Mutação: é empregado o operador de mutação polinomial em cada variável do indivíduo, com uma probabilidade p_m . Dada uma variável v , será produzida uma nova variável v' após a mutação dada por:

$$v' = v + \delta \cdot \Delta$$

em que: Δ representa o vetor diferença entre os valores máximos e mínimos dos parâmetros e δ possui distribuição de densidade polinomial e é dado por:

$$\delta = \begin{cases} (2r)^{\frac{1}{n_m+1}} - 1 : \text{se } r < 0.5 \\ 1 - [2(1-r)]^{\frac{1}{n_m+1}} : \text{se } r \geq 0.5 \end{cases}$$

onde: r é um número aleatório e n_m é o índice de distribuição de mutação.

Neste capítulo foram apresentados os fundamentos da otimização multiobjetivo, alguns métodos de solução e o algoritmo evolutivo multiobjetivo NSGA-II. A principal característica, e importante fator na escolha do método, é que um método evolutivo não requer características especiais nem das funções objetivo nem das restrições como derivadas contínuas, assim como alcança, a cada rodada, todo um conjunto de soluções diferentemente dos métodos clássicos.

4 *Construção do Modelo*

Os sistemas de reservatórios podem ser de um único ou de múltiplos reservatórios, associados em série e/ou em paralelo, e são compostos de maneira geral por: reservatórios, canais, túneis, tubulações, estações de bombeamento e centrais hidroelétricas. Estes sistemas podem suprir necessidades para o consumo humano, industrial e de irrigação; produção de hidroeletricidade, controle de enchentes, navegação e finalidades ecológicas, o que ilustra os múltiplos usos que podem ser dados à água de um sistema de reservatórios.

O gerenciamento destes sistemas, do ponto de vista do planejamento e da operação, é desafiador, uma vez que o problema envolve muitas variáveis complexas como aflúências, armazenamentos, transferências intra e/ou inter bacias de rios, entre outras.

O problema de otimização da operação de um sistema de múltiplos reservatórios é um problema de tratamento complexo devido:

- às características multiobjetivo, em consequência dos múltiplos usos conflitantes que podem ser dados à água, como por exemplo: garantir a navegabilidade e a proteção contra enchentes ou a geração de hidroeletricidade e a manutenção de um nível de segurança nos reservatórios;
- às não-linearidades que apresentam as funções objetivo e/ou as restrições como por exemplo, no caso da geração de energia, tanto a função de produção de energia, quanto a queda são funções do volume armazenado no reservatório;
- ao seu caráter dinâmico, devido à interdependência entre os estágios de tempo, ou seja, o valor atual da variável de decisão depende de seu valor no estágio de tempo anterior;
- à não-convexidade das funções;
- às diversas restrições de ordem física e operacional;

- ao acoplamento hidráulico entre os reservatórios, a montante e a jusante, onde a vazão afluente a um reservatório depende das vazões liberadas nos reservatórios imediatamente a montante; e
- ao caráter estocástico das afluições aos reservatórios, caracterizadas pelas condições climáticas da região onde estão localizados.

Neste capítulo faz-se uma apresentação das principais características e variáveis de um sistema de reservatórios, com o objetivo de descrever o modelo matemático que será utilizado na tese. Apresentam-se as funções objetivo e as restrições, visando os diferentes empregos ou usos para a água armazenada, dando especial ênfase à geração de energia elétrica.

4.1 Usinas Hidroelétricas

Uma central hidroelétrica, como a mostrada na Figura 7 e esquematizada na Figura 8, é composta, basicamente, por uma barragem que represa um rio formando o reservatório; por um sistema de condutos para dirigir a água até a casa de máquinas, onde se encontram instalados os grupos turbinas-geradores e demais equipamentos de controle e operação; além do canal de fuga, que tem a função de restituir a água turbinada ao mesmo rio ou a outro.

Outro componente importante da central é o vertedor que restitui ao rio a água não turbinada. O vertimento pode ocorrer em diversas situações, tais como: capacidade máxima do reservatório atingida e turbinamento insuficiente para controlar o nível, enquanto não foram instaladas todas as turbinas ou durante a parada para manutenção de máquinas do sistema hidroelétrico.

A diferença entre o nível de água de montante no reservatório (h_f) e o seu nível de jusante no canal de fuga (h_t) é chamada de altura de queda bruta (h_b). O nível da água no reservatório guarda uma relação não linear com o volume armazenado, enquanto o nível no canal de fuga depende, também não linearmente, da vazão defluente (soma das vazões turbinada e vertida). As características construtivas da usina determinam a influência da vazão vertida sobre o nível do canal de fuga. Esta poderá ser insignificante se o posicionamento do vertedor estiver afastado do ponto de descarga das turbinas (ENCINA, 2006), não afetando, dessa forma, a altura de queda bruta.

Listam-se, a seguir, as variáveis envolvidas no modelo de operação de uma usina



FIGURA 7: Hidroelétrica de Itumbiara - GO (fonte: ANEEL)




FIGURA 8: Representação esquemática de uma hidroelétrica (adaptado de (CICOGNA, 2003))

hidroelétrica, representadas na Figura 8 :

- V : volume armazenado no reservatório [hm^3]
- $\underline{V}$: volume mínimo operativo do reservatório [hm^3]
- $\overline{V}$: volume máximo operativo do reservatório [hm^3]
- $V_{util} = (\overline{V} - \underline{V})$: volume útil do reservatório [hm^3]
- Q^T : vazão turbinada pela usina [m^3/s]
- Q^v : vazão vertida pela usina [m^3/s]
- $Q^d = Q^T + Q^v$: vazão defluente da usina [m^3/s]
- $\phi(V)$: altura da cota de montante do reservatório (função do volume armazenado) [m]
- $\theta(Q^d)$: altura da cota de jusante do reservatório no canal de fuga (função da vazão defluente) [m]
- $h_b = \phi(V) - \theta(Q^d)$: altura de queda bruta [m]

4.2 Reservatórios

Os reservatórios obtidos pelas obras de barragem do rio podem ser classificados de acordo com a capacidade de regularização das vazões em: reservatórios de acumulação (ou regularização) e de compensação (ou captação). Os primeiros apresentam capacidade de regularização anual e até plurianual da vazão do rio. As centrais hidroelétricas, munidas com este tipo de reservatório, são denominadas usinas de reservatório ou de regularização. Já as que possuem reservatório de compensação não apresentam esta capacidade de regularização, sendo denominadas usinas a fio d'água ou de captação.

A classificação dos reservatórios apresentada acima está condicionada ao horizonte temporal de operação. Em horizontes de médio e longo prazo não se leva em conta a capacidade de regularização dos reservatórios a fio d'água, entretanto, em horizontes de curto prazo (diário ou horário) eles podem ser considerados na classe de acumulação (CICO GNA, 2003).

Nem todo o volume armazenado no reservatório pode ser utilizado para o propósito da geração de energia. A Figura 9 apresenta as divisões de volumes morto, útil e de segurança de acordo com o seu uso.

O volume armazenado abaixo da cota mínima operativa, definida por restrições hidráulicas, como por exemplo evitar vórtices na adução d'água ou a cavitação nas pás da turbina, é denominado de volume morto. Só é possível a geração de energia pela central com níveis superiores a esse volume.

O volume associado à operação da central hidroelétrica é denominado volume útil e é definido entre as alturas de cota mínima e máxima operativa.

Uma outra região do armazenamento, não menos importante, denominada volume de segurança, é o espaço vazio sobre a altura de cota máxima operativa e a altura de cota máxima *maximorum* do reservatório, destinado à regularização da cheia de projeto, definindo a máxima cota de operação da usina, que pode ser atingida apenas na condição emergencial da cheia de projeto. Essa condição é estabelecida no projeto diante de uma afluência hidrológica bastante majorada, calculada a partir do histórico de vazões e que representa a cheia mais severa para o aproveitamento em questão. Como exemplo, cita-se a cheia decamilenar muito empregada no cálculo das cheias de projeto dos reservatórios das usinas hidroelétricas brasileiras (CICOINA, 2003).




FIGURA 9: Representação das regiões do volume armazenado no reservatório (adaptado de Filho (2003))

4.3 Modelo Matemático do Sistema

4.3.1 Geração de Potência

A energia potencial armazenada na água dos reservatórios é convertida em energia elétrica por intermédio das turbinas hidráulicas e dos geradores elétricos. No processo de transformação da energia, nem toda aquela que está contida na água do reservatório poderá ser aproveitada na sua transformação em energia elétrica na saída do gerador.

Parcelas desta energia são perdidas em diferentes estágios do processo de conversão, como: na tomada d'água, nas tubulações forçadas ou de adução, na própria turbina hidráulica, na tubulação desde a saída da turbina até o canal de fuga, além das perdas no gerador elétrico.

A potência gerada numa usina hidroelétrica em um dado intervalo de tempo t , é dada pela equação integral da primeira lei da termodinâmica, sendo considerado regime permanente, escoamento incompressível, processo adiabático e energia interna constante:

$$\dot{W}_{i,t} = \eta_{i,t} Q_{i,t}^T \gamma_w h_{i,t} \quad (4.1)$$

onde $\dot{W}_{i,t}$ é a potência média expressa em W , $\eta_{i,t}$ é a eficiência média combinada dos grupos turbina e gerador elétrico, $Q_{i,t}^T$ é a vazão turbinada em m^3/s , γ_w é o peso específico da água expresso em N/m^3 , $h_{i,t}$ é a altura de queda bruta em m , sendo que o subíndice t indica o intervalo de tempo considerado e o subíndice i o reservatório.

É importante lembrar que na eficiência média η , além das perdas do conjunto turbina-gerador, incluem-se as perdas desde a tomada d'água até o canal de fuga. Assim, a eficiência média é função da altura de queda e da vazão turbinada, porém pode ser considerada constante no intervalo mensal (LOPES, 2007).

$$\dot{W}_{i,t} = \xi_{i,t} Q_{i,t}^T \quad (4.2)$$

onde $\xi_{i,t}$ é a função produtividade, que neste trabalho é determinada por um polinômio de quinto grau, em função do volume médio armazenado no reservatório durante o intervalo.

4.3.2 Restrições

O problema da otimização da operação de sistemas de reservatórios é sujeito a restrições de natureza física e operacional.

4.3.2.1 Conservação da Massa

Para garantir a conservação da massa num dado intervalo de tempo t , a variação do volume em cada reservatório entre o início do intervalo ($V_{i,t}$) e o final ($V_{i,t+1}$) deve ser igual ao volume produzido pela vazão de água afluyente ao reservatório ($Q_{i,t}^a$), deduzidas as vazões turbinada ($Q_{i,t}^T$) e vertida ($Q_{i,t}^v$).

$$V_{i,t+1} - V_{i,t} = (Q_{i,t}^a - Q_{i,t}^T - Q_{i,t}^v)\Delta t_t \quad (4.3)$$

Se os volumes armazenados em cada reservatório, ao final de cada intervalo de tempo, são tomados como variáveis de decisão do problema, a soma das vazões defluentes (turbinada e vertida) a cada intervalo pode ser facilmente determinada.

$$Q_{i,t}^d = Q_{i,t}^T + Q_{i,t}^v = Q_{i,t}^a - \left(\frac{V_{i,t+1} - V_{i,t}}{\Delta t_t} \right) \quad (4.4)$$

No caso do reservatório ser o primeiro na cascata de reservatórios no rio, reservatórios 1, 3 e 4 da Figura 10, a vazão afluyente será a natural, caso contrário, como os reservatórios 2 e 5, a vazão afluyente é a soma da vazão defluente dos reservatórios imediatamente a montante do mesmo e da vazão incremental, aquela que é adicionada entre os reservatórios, em especial por afluentes ao rio. Dessa forma, a vazão afluyente ao reservatório será determinada pela expressão:

$$Q_{i,t}^a = \sum_{k=1, k \in U}^N (Q_{k,t}^T + Q_{k,t}^v) + Q_{i,t}^I \quad (4.5)$$

onde U é o conjunto de reservatórios imediatamente a montante do reservatório i e $Q_{i,t}^I$ representa a vazão incremental no intervalo t a este reservatório.




FIGURA 10: Esquema de composição das vazões afluentes em cada reservatório.

A conservação da massa estabelece uma relação direta entre o volume de água descarregado no canal de fuga e o volume do reservatório, uma vez que o volume afluente é conhecido, respeitando-se o cálculo sequencial de montante para jusante na cascata de reservatórios.

4.3.2.2 Limites Operacionais

O volume de água em cada reservatório é limitado no nível inferior pelo nível da tomada d'água, e no nível superior pelo limite estrutural da barragem.

$$V_i^{min} \leq V_{i,t} \leq V_i^{max} \quad (4.6)$$

Os parâmetros operacionais das turbinas e dos geradores também impõem restrições ao problema, em termos da potência máxima gerada e da máxima vazão turbinada admissível. Neste trabalho considera-se que, em cada reservatório, todas as turbinas são idênticas e estão sempre disponíveis para operação.

Os conceitos discutidos a seguir se referem à análise para uma unidade geradora (grupo turbina/gerador). Porém, são extensíveis à análise da central, que é composta por conjuntos destas unidades geradoras. Como observado na figura 11, a potência gerada pelo conjunto turbina-gerador apresenta duas regiões com comportamentos distintos, separadas pelo valor da altura de queda efetiva.




FIGURA 11: Esquema das curvas Potência x Altura de Queda Líquida e Vazão x Altura de Queda Líquida para um conjunto turbina gerador (CICO GNA, 2003).

Nota-se que para operação com valores de queda abaixo da efetiva, a turbina limita a produção de potência. Nessa região, mesmo com a abertura total das pás do sistema diretor, a vazão através da turbina é insuficiente para produzir a potência máxima. A

maior vazão admitida e, conseqüentemente, a potência gerada cresce com o aumento da queda líquida.

Por outro lado, quando o conjunto opera com alturas de queda líquida maiores que a efetiva, a produção de potência é limitada pelo gerador. Para que este produza não mais que potência elétrica nominal, limita-se a potência mecânica a ele fornecida por meio da redução da vazão admitida pela turbina. Define-se, então, que o engolimento máximo do conjunto turbina-gerador como a vazão turbinada que, quando submetida a queda efetiva, produz a potência máxima da unidade (CICOGNA, 2003).

$$\dot{W}_{i,t} \leq \dot{W}_i^{\max} \quad (4.7)$$

$$Q_{i,t}^T \leq Q_i^{T,\max} \quad (4.8)$$

As informações disponíveis fazem com que um modelo simplificado seja empregado neste trabalho. Neste modelo, na primeira região, aquela em que a queda líquida é menor que a altura de queda efetiva, impõe-se apenas a limitação de vazão inferior ao engolimento máximo do sistema, uma vez que não se dispõe das curvas de variação da vazão máxima com a queda líquida. Na segunda região, considera-se que o sistema segue o comportamento descrito anteriormente.

Dessa forma, para as duas regiões, o limite da vazão admitida pelo sistema de turbinas é determinado pelo menor valor entre o engolimento máximo das turbinas e o valor da vazão, que define a potência máxima de cada central hidroelétrica para o volume armazenado e, portanto, a queda líquida no reservatório.

$$Q_i^{T,\max} = \min\{Q_{i,t}^{\max \text{ pot}}, Q_i^{\text{turb max}}\} \quad (4.9)$$

Assume-se haver vazão pelo vertedor se a vazão defluente, determinada pela variação do volume em um reservatório em dado intervalo (conservação da massa), excede essa vazão máxima.

$$Q_{i,t}^T = \min\{Q_{i,t}^d, Q_i^{T,\max}\} \quad (4.10)$$

$$Q_{i,t}^v = \max\{Q_{i,t}^d - Q_i^{T,\max}, 0\} \quad (4.11)$$

Uma vazão mínima de restituição ao rio $Q_i^{\min}$ para cada reservatório deve ser garantida, por razões ecológicas, sanitárias e econômicas. Como aqui se considera que as turbinas estão sempre disponíveis, essa vazão mínima é sempre empregada na geração de

potência.

$$Q_i^{min} \leq Q_{i,t}^T \quad (4.12)$$

Finalmente, é necessário impor uma condição final para o volume armazenado nos reservatórios. Neste trabalho, assume-se que os reservatórios devem retornar à condição inicial, isto é, que

$$V_{i,0} = V_{i,N} \quad (4.13)$$

No algoritmo de otimização, esta restrição foi implementada reduzindo em um o número de variáveis de decisão e fixando o volume ao final do último intervalo.

4.4 Modelo de Otimização do Sistema

Diversos e variados objetivos conflitantes são encontrados nos trabalhos da literatura sobre otimização da operação de sistemas de reservatórios. Cada um deles representa uma medida quantitativa de um diferente aspecto da operação do sistema energético e dos reservatórios abordados. Apresentam-se a seguir algumas dessas funções objetivo.

Neste trabalho são estudadas duas funções objetivo que representam aspectos fundamentais da operação de sistemas energéticos: a maximização da geração da energia e da menor energia gerada em um período. Uma terceira função objetivo, ligada a navegabilidade de um trecho de rio, também é estudada, ilustrando o caráter multiuso da água dos reservatórios.

Considerando como o horizonte de operação um período T de tempo, dividido em M intervalos de tempo e um sistema composto por N reservatórios. Serão ainda apresentados nesta seção alguns objetivos utilizados no multiuso das águas dos reservatórios.

4.4.1 Funções Objetivo de Geração de Hidroeletricidade

4.4.1.1 Maximizar a Potência Média Gerada

O primeiro objetivo, maximização da potência média gerada, está diretamente relacionado à energia total gerada pelo sistema de hidroelétricas e, em termos econômicos ao

faturamento do sistema.

$$\max \bar{W} = \frac{1}{\sum_{t=1}^M \Delta t_t} \sum_{t=1}^M \sum_{i=1}^N \dot{W}_{i,t} \Delta t_t \quad (4.14)$$

onde N é o número de reservatórios e M é o número de meses considerados.

4.4.1.2 Maximizar a Mínima Potência Gerada

O segundo objetivo é a maximização da mínima potência gerada mensalmente, o que equivale a minimizar o custo com instalações para geração da energia complementar.

$$\max \dot{W}_{\min} = \min_t \sum_{i=1}^N \dot{W}_{i,t} \quad \forall t \in \{1, 2, \dots, M\} \quad (4.15)$$

Esse objetivo torna-se particularmente importante quando o regime pluviométrico está sujeito a grandes variações que, na ausência de um grande reservatório, produziriam variações correspondentes na geração de potência. A potência complementar necessária é geralmente proveniente de fontes de combustíveis fósseis ou nucleares, cujos custos são mais elevados e apresentam, sobretudo, maior impacto ambiental.

4.4.1.3 Minimizar a Complementação da Energia

Quando o método de otimização utilizado exige uma função objetivo de derivada contínua, o objetivo anterior é aproximado pelo somatório do quadrado da diferença entre a demanda e a potência gerada (SHARMA *et al.*, 2004; BARROS *et al.*, 2003):

$$\min W_{CE} = \sum_{t=1}^M \left(D_T - \sum_{i=1}^N \dot{W}_i \right)^2, \quad (4.16)$$

onde D_T é a demanda total de energia, que será sempre superior à capacidade da usina, pois inclui outras usinas hidroelétricas, além de outras fontes energéticas. O propósito deste objetivo é o mesmo do anterior, ou seja, minimizar os custos com instalações e operação para suprir a energia complementar.

4.4.1.4 Minimizar a Energia Vertida

Mesmo em reservatórios isolados há momentos em que é necessário usar o vertedouro, por exemplo, quando o volume do reservatório está em seu limite superior e a vazão afluente é maior que máxima vazão turbinada. O objetivo de reduzir a energia que deixa

de ser produzida quando água é vertida, é expresso como (BARROS *et al.*, 2005):

$$\min W_{\text{VERT}} = \min \sum_{i=1}^N \sum_{t=1}^M \xi_{i,t} Q_{i,t}^v \Delta t_t, \quad (4.17)$$

onde $Q_{i,t}^s$ é a vazão vertida no reservatório i e no intervalo de tempo t .

4.4.1.5 Maximizar o Lucro Derivado da Energia Secundária

No sistema elétrico brasileiro, define-se a energia assegurada como a máxima produção de energia que pode ser mantida quase que continuamente pelas usinas hidrelétricas ao longo dos anos, admitindo risco de não atendimento a carga inferior a 5%. O montante produzido acima desse valor é denominado energia secundária e tem preço de venda normalmente inferior ao da energia assegurada. Barros *et al.* (2003) propuseram a seguinte formulação para a maximização do lucro com a venda da energia secundária:

$$\max \sum_{t=1}^M \left(p_t \left(\sum_{i=1}^N W_{t,i} - D_c \right) \right) \quad (4.18)$$

onde: p_t é o preço esperado no mercado de energia no tempo t e D_c é a demanda contratada (energia firme ou assegurada), que não está disponível para venda no mercado *spot*.

4.4.2 Outras Funções Objetivo

4.4.2.1 Maximização da Vazão Defluente Mínima-Navegabilidade

Muitos rios apresentam grandes variações sazonais em seu nível de água, permitindo que navios de maior porte só possam navegar em parte do ano. A vazão nesses rios pode ser regularizada pelos reservatórios, tornando-os navegáveis durante todo o ano. A manutenção de maiores valores de vazão defluente mínima no reservatório permite a navegação destas embarcações de maior porte no trecho de rio a sua jusante.

$$\max \min_t Q_{t,i}^d \quad (4.19)$$

A otimização desse objetivo leva à maximização da mínima vazão defluente a jusante do reservatório i .

4.4.2.2 Minimizar o Desvio da Meta de Volume Armazenado

Estabelecida uma meta para o volume mensal de cada reservatório (S_i), pode-se propor como objetivo a soma no tempo do desvio quadrático entre a meta e o volume armazenado em cada reservatório (BARROS *et al.*, 2005):

$$\min \sum_{t=1}^M \sum_{i=1}^N (S_{i,t} - V_{i,t})^2, \quad (4.20)$$

Uma versão para este objetivo, com derivada descontínua, poderia ser proposta na forma:

$$\min \max(S_t - V_t) \quad \forall i \in \{1, 2, \dots, N\}, \quad (4.21)$$

com a vantagem de que somente seriam considerados os finais de período em que o volume armazenado fosse inferior à meta.

4.4.2.3 Suprimento de água para abastecimento de cidades, indústrias e irrigação

Uma expressão bastante empregada na literatura (BRANDÃO, 2004) é minimizar o desvio padrão entre o suprimento e a demanda para cada intervalo de tempo em cada reservatório:

$$\min \sum_{t=1}^M \sum_{i=1}^N (Qab_{i,t} - Dab_{i,t})^2 \quad (4.22)$$

onde $Qab_{i,t}$ é a vazão desviada do reservatório i e no intervalo de tempo t para o abastecimento, e $Dab_{i,t}$ a demanda por suprimento de água naquele intervalo de tempo e reservatório.

4.4.2.4 Controle de Cheias

O controle da vazão a jusante de um reservatório contribui para evitar a inundação de áreas urbanas e agrícolas. Quando métodos determinísticos são empregados, é necessário expressar esse objetivo na forma de uma função de derivada primeira contínua, como a seguinte (BRANDÃO, 2004):

$$\min \sum_{t=1}^M \sum_{i=1}^N (Q_{i,t}^d - Q_{i,t}^{cc})^2 \quad (4.23)$$

onde $Q_{i,t}^{cc}$ é um valor limite de vazão a jusante do reservatório i , a partir do qual começam a ocorrer problemas de inundação. Essa forma impõe punição tanto quando a vazão excede o limite quanto quando ela é inferior a este.

Quando se empregam métodos evolutivos, não há necessidade da continuidade da derivada da função objetivo e formas mais aperfeiçoadas podem ser empregadas, considerando apenas os intervalos em que a vazão excede o limite, como aqui propomos:

$$\min \sum_{t=1}^M \sum_{i=1}^N \max(Q_{i,t}^d - Q_{i,t}^{cc}, 0) \quad (4.24)$$

Neste capítulo foram apresentados os elementos básicos componentes de uma central hidroelétrica, as variáveis envolvidas na operação e otimização de um sistema de reservatórios, as funções objetivo que podem ser utilizadas na otimização e as restrições físicas e operacionais envolvidas no processo de otimização da operação de um sistema de reservatórios.

5 *Proposta desenvolvida*

Apresenta-se, a seguir, a proposta de um modelo inédito de otimização multiobjetivo, irrestrito e limitado, com o aprimoramento do desempenho do algoritmo evolutivo multiobjetivo clássico NSGA-II, no tratamento do problema da otimização da operação de sistemas de reservatórios múltiplos.

O NSGA-II é utilizado como algoritmo base sendo modificado para lidar com as características específicas do problema. A principal modificação, que causa maior avanço no desempenho do algoritmo, é um novo esquema de codificação que permite o manuseio implícito de várias restrições envolvidas no problema. Esse esquema evoluiu a partir de três alternativas de tratamento das restrições de conservação da massa e dos limites máximo e mínimo do volume armazenado no reservatório.

5.1 Modificações ao NSGA-II

Inicialmente, empregou-se o algoritmo NSGA-II padrão com a factibilidade sendo tratada como parte do operador de seleção (DEB *et al.*, 2000). Foram utilizados dois operadores de cruzamento e dois de mutação, cujos detalhes serão descritos a seguir. Ressalta-se aqui que existem muitas outras escolhas de operadores de cruzamento e mutação à disposição do usuário de algoritmos genéticos.

5.1.1 Operadores

Os operadores específicos utilizados no NSGA-II são apresentados nesta seção. Dois operadores, tanto para cruzamento quanto para a mutação, foram empregados.

5.1.1.1 Cruzamento

Para cada par formado no processo de seleção, que segue o procedimento proposto por Deb *et al.* (2002), verifica-se a ocorrência ou não do cruzamento com uma probabilidade de ocorrência (p_{cross}). Foram empregados dois operadores, sendo o primeiro, com 70% de probabilidade de ocorrência, um operador linear com tendência às vizinhanças do pai de melhor aptidão e o outro, um operador de cruzamento linear sem tendência. Cada um dos dois operadores mencionados serão descritos a seguir:

- Cruzamento Linear sem Tendência

Se o pai_a for mais apto que o pai_b :

$$x^g = x^a + \rho * (x^b - x^a) \quad (5.1)$$

onde ρ é um número aleatório com distribuição uniforme de ocorrência no intervalo $[-0.4, 1.4]$.

- Cruzamento Linear com Tendência

$$x^g = x^a + \rho * (x^b - x^a) \quad (5.2)$$

onde $\rho = 1, 4\beta - 0, 2$, em que β é um número aleatório gerado com distribuição de probabilidade Beta, com parâmetros 2 e 5, no intervalo $[0, 1]$, ver Figura 12 para a distribuição de probabilidades Beta.

Ambos operadores de cruzamento utilizados são denominados operadores de recombinação intermediários, aritméticos ou convexos com extrapolação nas extremidades, onde o novo indivíduo é gerado por uma combinação convexa das variáveis dos indivíduos pais. Como o número aleatório ρ é o mesmo para todas as variáveis, a localização do indivíduo gerado recai sobre o segmento de reta que liga os dois indivíduos pais, com uma extrapolação nas duas extremidades.

5.1.1.2 Mutação

A finalidade do operador de mutação é introduzir novas informações genéticas na população após a operação de cruzamento, com o objetivo de aumentar a diversidade da mesma. Com a introdução dessas alterações nos indivíduos, novas regiões da região de busca podem ser exploradas.




FIGURA 12: Distribuição de probabilidades Beta.

Na codificação real, em geral, os operadores de mutação introduzem uma perturbação nos indivíduos da população com uma probabilidade de ocorrência de p_{mut} , conforme a equação:

$$x^m = x + \delta \quad (5.3)$$

onde x^m é o indivíduo mutado e δ representa o vetor de perturbações que o indivíduo pode sofrer dado por:

$$\delta = \gamma * r_{mut}/k \quad (5.4)$$

em que γ é um número aleatório com distribuição gaussiana, com média zero e variância um; r_{mut} é o vetor de diferença entre os valores máximos e mínimos das variáveis a serem mudadas, e k é uma constante que controla o intervalo relativo da mutação.

Estuda-se aqui duas possibilidades de mutação: uma por indivíduo e outra por variável. No primeiro operador de mutação, quando ocorrer, o novo indivíduo sofrerá alteração em todas as suas variáveis, sendo constituído pelo seu valor após o cruzamento adicionado de uma fração da maior diferença entre as variáveis dos indivíduos anteriores ao cruzamento, submetida a uma distribuição normal de probabilidades.

No operador de mutação por variável, primeiramente é feito um sorteio aleatório com distribuição uniforme de quais variáveis sofrerão mutação na população pós cruzamento.

As variáveis selecionadas sofrerão, assim, mutação segundo a equação descrita acima.

Como será mostrado no capítulo de experimentos computacionais, o operador de mutação por indivíduo não logra bom desempenho no tratamento do problema com sistemas de reservatórios, exigindo que se utilize um operador de mutação por variável.

5.2 Evolução de Alternativas no Tratamento das Restrições

No capítulo de resultados será mostrado que as restrições não lineares representam um problema para o algoritmo genético, que tem dificuldade para encontrar indivíduos factíveis. Como resultado, a população do algoritmo genético que resolve o problema descrito na seção 4.3 apresenta perda de diversidade e a frente de Pareto produzida cobre somente um pequeno intervalo das funções objetivo.

Com o intuito de identificar a origem e promover melhorias dos resultados insatisfatórios obtidos pela aplicação da metodologia ao modelo do problema apresentado, estabeleceu-se a seguinte estratégia. Primeiro, para uma configuração de usina única, três abordagens foram testadas no enfrentamento do problema, obtendo-se avanços progressivos na qualidade dos resultados a serem apresentados no respectivo capítulo. Em etapa posterior, a formulação que proporcionou maiores ganhos foi implementada em um sistema de múltiplos reservatórios. As três abordagens são apresentadas a seguir:

- Gerar uma população inicial com indivíduos factíveis ou quase factíveis;
- Reduzir o domínio das variáveis de decisão; e
- Converter o problema original restrito em um problema irrestrito.

5.2.1 Redução do Número de Indivíduos Infactíveis na População Inicial

Em experimentos preliminares verificou-se que o algoritmo de otimização não era capaz de gerar indivíduos factíveis, quando a população inicial era gerada de forma aleatória sobre todo o domínio das variáveis de decisão. Por outro lado, observou-se a possibilidade de gerar uma população inicial composta apenas por indivíduos factíveis ou, se infactíveis, próximos à região factível, com poucas restrições violadas e/ou com pequenas violações (quase factíveis). Para tanto, mantiveram-se os valores das variáveis de decisão,

os volumes do reservatório mês a mês, dentro da estreita faixa, entre 85% e 100% do volume máximo do reservatório. Esta abordagem será doravante denominada “formulação básica”.

5.2.2 Redução do Domínio da Variáveis de Decisão

Observou-se que a maioria dos indivíduos ineficazes eram relacionados à necessidade de recuperação do volume do reservatório. Esta capacidade de recuperação, para cada intervalo de tempo, é limitada em seu valor máximo pela diferença entre o volume afluente ao reservatório e o volume turbinado mínimo. Se ao final de qualquer intervalo o seu volume fosse significativamente menor que o inicial e a vazão afluente ao reservatório fosse insuficiente para recuperá-lo, a conservação da massa produziria uma vazão turbinada ineficaz, podendo ser até mesmo negativa. Para enfrentar tal problema, ao invés de impor um limite inferior único para o volume mínimo do reservatório, durante todo o período de otimização, foi imposto um limite mínimo para cada intervalo dado pela equação

$$V_{t-1}^{min} = V_t^{min} - (Q_t^a - Q^{T,min})\Delta t_t \quad \forall t \in \{1, 2, \dots, M - 1\} \quad (5.5)$$

O limite inferior para o volume no início de cada intervalo de tempo é igual ao volume mínimo ao final do mesmo intervalo, deduzida a diferença entre o volume afluente e o volume turbinado mínimo naquele intervalo. Como o volume final do período de otimização é conhecido, o conjunto de limites inferiores para o volume é determinado pela equação precedente para cada intervalo, do último para o primeiro, antes de se iniciar a otimização. O limite inferior para cada intervalo encontra-se representado graficamente, pela curva em vermelho, para um conjunto de estados arbitrários do reservatório na figura 13.

5.2.3 Formulação Irrestrita

Mesmo com melhoria da formulação obtida com a adoção do limite inferior do volume para cada intervalo, uma parte significativa dos indivíduos gerados ainda era ineficaz. Este comportamento era mais pronunciado quando o reservatório enchia novamente, antes da estação mais seca. Aqui, também, a vazão afluente se mostrava insuficiente para permitir qualquer aumento no volume, até o limite máximo estabelecido, mantida a vazão turbinada mínima. Assim, propôs-se uma modificação para o limite superior do volume em cada intervalo, de forma a respeitar a máxima capacidade de recuperação do volume




FIGURA 13: Limites do volume do reservatório para cada intervalo de tempo: inferior, curva em vermelho e superior, curva em verde. A curva em azul representa as frações de volumes assumidas por um indivíduo arbitrário da população.

armazenado.

$$V_{t+1}^{max} = \begin{cases} V_t + (Q_t^a - Q^{T,min})\Delta t_t, & \text{se } < V^{max} \\ V^{max}, & \text{de outra forma} \end{cases} \quad \forall t \in \{1, 2, \dots, M - 1\} \quad (5.6)$$

O limite superior para o volume do reservatório, ao final de um dado intervalo, é dado pelo menor valor entre o volume máximo permitido ao reservatório e o valor determinado pela soma do volume no início deste intervalo com a diferença entre o volume afluyente e o mínimo turbinado neste mesmo intervalo.

Importante ressaltar que o valor do limite superior ao final de cada intervalo é dependente do valor do volume no início daquele intervalo, uma vez que seu valor é fruto da decisão no intervalo anterior. Por esta razão, diferentemente da obtenção do limite inferior para o volume a cada intervalo, que podia ser determinado previamente à otimização, neste caso, o limite superior para o volume só pode ser determinado para cada indivíduo da população. O limite superior para cada intervalo encontra-se representado graficamente, pela curva em verde, para um conjunto de estados arbitrários do reservatório na figura 13.

Mesmo com a imposição de um limite superior para o volume a cada intervalo, o

algoritmo ainda pode gerar muitos indivíduos inefectivos, criando a necessidade de um operador de correção para trazer as variáveis de decisão para o interior da faixa factível. Para evitar a utilização de tal corretor, o trabalho propõe, de forma inédita, uma formulação irrestrita, mas com domínio definido (SCOLA *et al.*, 2010), combinando ambos os limites, inferior e superior, para o volume do reservatório a cada intervalo de tempo. As variáveis de decisão deixam de ser os volumes e passam, agora, a ser frações (α) dos volumes disponíveis mensalmente, variando entre valores de zero a um. Ao volume mínimo corresponde um valor de α igual a zero; ao volume máximo tem-se um como valor correspondente para o intervalo de tempo, conforme representado na Figura 13.

$$V_i = V_i^{min} + \alpha_i (V_i^{max} - V_i^{min}), \alpha \in [0, 1] \quad (5.7)$$

Dentro destes limites, as vazões turbinadas são sempre maiores que a mínima, embora ainda possam tanto levar a potências geradas maiores que a máxima permitida quanto ultrapassarem o limite da vazão máxima. Para lidar com esses casos, assume-se que uma parcela da vazão foi vertida e que a vazão verdadeira através da turbina é a que satisfaz ambas as restrições Equações (4.7) e (4.8).

Ao final foi proposto um modelo de otimização multiobjetivo irrestrito e limitado, para superar os problemas encontrados com a falta de diversidade e convergência prematura, permitindo a obtenção de curvas de Pareto bem povoadas e com boa amplitude. Reduz-se, assim, o gargalo computacional apresentado pela formulação original do modelo, quando aplicado ao problema da otimização multiobjetivo da operação de múltiplos reservatórios.

6 *Experimentos Computacionais, Resultados e Análises*

Para demonstrar as diferentes fases na evolução da metodologia proposta, são apresentados e comparados os resultados da aplicação de três diferentes formulações para manipular as restrições em um sistema de um único reservatório, com a finalidade de verificar o seu desempenho para um período de otimização de 12 meses. As duas primeiras alternativas de manipulação empregam no modelo o volume armazenado no reservatório como variável de decisão. A terceira utiliza no modelo, como variável de decisão, a fração de volume α .

Posteriormente, demonstra-se a capacidade da metodologia para tratar sistemas de maior complexidade, a partir de experimentos realizados com um sistema de cinco reservatórios, em uma única bacia hidrográfica composta por três rios principais, com acoplamento hidráulico entre os reservatórios.

Na primeira tentativa da extensão da metodologia à aplicação em sistemas de múltiplos reservatórios o operador de mutação que fora empregado na otimização com único reservatório mostrou-se ineficiente, o que levou à proposição de um novo operador de mutação conforme será mostrado na seção (6.2.1).

Após a definição de um novo operador de mutação, primeiramente, procedeu-se a uma análise de sensibilidade das soluções aos parâmetros do algoritmo genético no sistema estudado, utilizando-se para isto no modelo as funções objetivo reais. Em seguida, a metodologia foi utilizada em quatro cenários para um ano tipicamente chuvoso e para um ano tipicamente seco.

O primeiro cenário foi definido para avaliar o desempenho da metodologia proposta, a partir de considerações puramente de geração de energia, obtendo-se a curva de Pareto da potência média produzida *versus* a máxima mínima potência. Para o segundo, adicionam-se ao primeiro cenário considerações socioambientais, relativas à manutenção da navegabilidade de um trecho do rio.

No terceiro cenário considerou-se aspectos relativos à segurança energética e a robustez do sistema, partindo-se de diferentes condições iniciais e finais do volume do reservatório. Por último, foi realizada a otimização para um período de prazo mais longo, 36 meses. Os resultados obtidos nesta otimização de longo prazo são comparados com uma combinação das soluções eficientes obtidas em separado para cada ano do período.

Para os quatro cenários foram implementados dois objetivos ligados à geração de energia elétrica: Maximização da Potência Média e Maximização da Menor Potência Gerada. No segundo cenário, além desses dois objetivos, inclui-se um terceiro objetivo ligado à navegabilidade de um trecho do rio, empregando-se, o método ε -restrito.

6.1 Análise do Caso do Sistema com um único Reservatório

6.1.1 Detalhamento do Caso

A usina estudada foi a hidroelétrica Nova Ponte, no leito do rio Araguari, concluída em 1994. Este foi um dos últimos grandes reservatórios construídos no sudeste brasileiro. Operada pela Companhia Energética de Minas Gerais (CEMIG), seu reservatório apresenta capacidade máxima de armazenamento de 12.792 hm^3 , apresentando um volume mínimo de operação de 2.412 hm^3 . Está equipada com três turbinas hidráulicas tipo Francis que juntas admitem um mínimo de $125 \text{ m}^3/\text{s}$ e um máximo de $510 \text{ m}^3/\text{s}$ de água, com potência nominal total de 510 MW.

O clima na região da bacia do rio Araguari é caracterizado por duas estações bem definidas. A primeira, a estação seca, entre os meses de abril e setembro, e a segunda, chuvosa, estendendo-se de outubro a março, como pode ser observado através de dados estatísticos na Figura 14. Nesta figura são apresentadas as vazões naturais afluentes ao reservatório, mês a mês, entre 1931 e 2012. Em termos médios $124 \text{ m}^3/\text{s}$ de água chegam ao reservatório no mês de setembro, quando se observa a menor média mensal do período, cerca de um quarto dos $537 \text{ m}^3/\text{s}$ observados em fevereiro, mês em que é maior a vazão afluente média e que também foi registrada a afluência máxima histórica de $1243 \text{ m}^3/\text{s}$.

A função de produtividade (Equação 4.2) da usina de Nova Ponte, empregada para determinar a potência gerada em um determinado período, é aproximada pelo seguinte polinômio de quinto grau, determinado pelo Operador Nacional do Sistema (ONS) e




FIGURA 14: *Boxplot* mês a mês das vazões naturais médias mensais para o reservatório de Nova Ponte-MG, no período entre os anos de 1931 e 2012 (Fonte: http://www.ons.org.br/operacao/vazoes_naturais.aspx)

fornecido pela operadora CEMIG.

$$\begin{aligned} \xi_t = & 1.95365 \cdot 10^{-21} \bar{V}_t^5 - 6.49561 \cdot 10^{-17} \bar{V}_t^4 + \\ & 9.11797 \cdot 10^{-13} \bar{V}_t^3 - 7.87711 \cdot 10^{-09} \bar{V}_t^2 + \\ & 6.84174 \cdot 10^{-05} \bar{V}_t + 0.72616 \quad (6.1) \end{aligned}$$

onde $\bar{V}_t = (V_t + V_{t-1})/2$.

6.1.2 Resultados e Análises

Experimentos preliminares mostram que o algoritmo de otimização com o modelo empregado não foi capaz de gerar indivíduos factíveis, quando a população inicial era gerada de forma aleatória sobre todo o domínio das variáveis de decisão. A primeira formulação empregada, denominada formulação básica, utiliza como variáveis de decisão o volume do reservatório ao final de cada intervalo, limitando sua variação a uma faixa de 85% a 100% do volume máximo do reservatório, (limites fixados entre diversas tentativas ensaiadas). Como descrito no item 4.3.2, outras restrições também são impostas, tanto físicas, como a conservação da massa, que relaciona os volumes no início e no final do

período com a vazão defluente; como técnicas, tais como os limites para a potência gerada e as vazões turbinadas mínima e máxima. O tratamento da factibilidade foi feito da forma apresentada por Deb *et al.* (2000), isto é, como parte do operador de seleção.

Os experimentos foram realizados com dados de um ano chuvoso típico (de maio de 1976 a abril de 1977), com os volumes do reservatório, no início e no final da otimização, fixados em 95 por cento do máximo permitido.

Empregando esta formulação, poucos dos experimentos realizados produziram populações com indivíduos factíveis, mesmo quando a população inicial foi trabalhada para incluir somente indivíduos factíveis ou quase factíveis. As frentes de Pareto para 8 desses experimentos, com populações de 400 indivíduos e 5000 gerações, são apresentadas na Figura 15. O primeiro objetivo, a energia total gerada (MWh), é mostrada no eixo horizontal e o segundo objetivo, a mínima potência gerada (MW), está representada no eixo vertical. Em todos os testes, as frentes de Pareto apresentam-se estreitas, estendendo-se mais em direção ao primeiro objetivo.




FIGURA 15: Conjuntos eficientes para 8 execuções da formulação básica, com 400 indivíduos e 5000 gerações

A segunda formulação testada, denominada redução do domínio das variáveis de decisão, é a descrita no item 5.2.2 e corresponde à imposição de um limite inferior variável, intervalo a intervalo, para o volume do reservatório, baseado nas necessidades de recuperação ao longo do período simulado. Nesta formulação, onde o algoritmo foi executado 21 vezes, com 400 indivíduos e 2500 gerações, as variáveis de decisão e as restrições são

as mesmas da formulação básica.

Conforme mostrado na Figura 16, a formulação da redução do domínio das variáveis de decisão obteve uma frente de Pareto completamente povoada, mas com grande dispersão nos resultados entre as execuções. Algumas das frentes são mesmo inferiores às aquelas encontradas com a formulação básica, mas nos experimentos com a segunda formulação a população inicial foi gerada aleatoriamente e o número de gerações é a metade do usado anteriormente, tornando a comparação imprópria.




FIGURA 16: Conjuntos eficientes para 21 execuções da formulação da redução do domínio das variáveis de decisão, com 400 indivíduos e 2500 gerações

A terceira formulação proposta é denominada irrestrita (item 5.2.3). Nela, as variáveis de decisão são as frações da diferença entre os volumes máximo e mínimo fisicamente viáveis, considerando a conservação da massa e o volume turbinado mínimo. Também nesta formulação foram adotados os mesmos parâmetros de execução da segunda formulação.

A formulação irrestrita produz a cada execução uma frente de Pareto ampla e bem povoada, conforme mostra a Figura 17. Na Figura 18, são apresentadas todas as soluções eficientes e as frentes de Pareto combinadas para a segunda e terceira formulações. É evidente, nesses experimentos, que a formulação irrestrita gera melhores resultados, produzindo em todos as frentes mais amplas, que se comparam ou até mesmo superam a frente de Pareto obtida pela combinação dos resultados da formulação da redução do domínio das variáveis de decisão.




FIGURA 17: Conjuntos eficientes para 21 execuções da formulação irrestrita, com 400 indivíduos e 2500 gerações




FIGURA 18: Conjuntos eficientes para cada execução das formulações da redução de domínio das variáveis de decisão e da irrestrita, com as respectivas frentes de Pareto combinadas

No que tange à operação da usina hidroelétrica com base na Figura 17, dentre os pontos eficientes gerados pela formulação irrestrita, a menor potência mínima gerada tem um valor de 141,8 MW, correspondendo a energia máxima produzida de $2,718 \times 10^3$ GWh. No outro extremo da frente de Pareto, a maior potência mínima gerada foi de 297,6 MW, com $2,643 \times 10^3$ GWh de energia gerada.

As Figuras 19 e 20 mostram as potências geradas mensalmente para estes extremos respectivamente, onde as barras representam a potência gerada mês a mês, e a linha contínua em verde, o volume armazenado no reservatório.




FIGURA 19: Potência mensal gerada e volume do reservatório para o ponto extremo com a menor mínima potência gerada e a maior geração de energia

Na primeira solução extrema, menor mínima potência gerada e maior geração de energia, durante a estação seca do ano em análise, a potência gerada é mantida no mínimo e o reservatório acumula água. Quando chegam as chuvas, a potência gerada é aumentada com o crescimento do nível do reservatório, assegurando elevada potência por unidade de massa de água turbinada.

Na segunda solução extrema, maior mínima potência gerada e menor geração de energia, o volume do reservatório varia consideravelmente, diminuindo durante a estação seca e recuperando durante a estação chuvosa. A geração é mantida estável, com uma perda de 25 GWh na comparação com o outro extremo.

Ao final do período de otimização, para ambos os pontos extremos da curva de Pareto analisados, o volume do reservatório recupera a condição inicial como foi imposta no




FIGURA 20: Potência mensal gerada e volume do reservatório para o ponto extremo com a maior mínima potência gerada e a menor geração de energia

modelo.

6.2 A Bacia com Cinco Reservatórios

Para avaliar a extensão da metodologia a sistemas de múltiplos reservatórios, foi estudado um subsistema do Sistema Integrado Nacional, constituído por cinco usinas hidroelétricas na Bacia do Rio Paranaíba, com uma potência instalada total de 4.765 MW (ver Figura 21).

Três destas cinco centrais se encontram instaladas sobre afluentes do Rio Paranaíba, duas sobre o Rio Araguari, Nova Ponte com 510 MW e a jusante Miranda com 408 MW, e uma única sobre o Rio Corumbá, a central de Corumbá I com 375 MW de potência instalada.

Sobre o Rio Paranaíba propriamente, encontram-se as duas maiores usinas do complexo considerado: Emborcação, com potência instalada de 1.192 MW, situada a montante do entroncamento dos Rios Araguari e Corumbá com o Paranaíba; e a central de Itumbiara com 2.280 MW, a jusante do entrocamento. As características climáticas da região afetam a vazão natural afluyente a cada reservatório. O Operador Nacional do Sistema Elétrico (ONS) disponibiliza séries históricas das vazões naturais médias diárias e mensais desde 1931.




FIGURA 21: Esquema do micro sistema das cinco centrais.

Entende-se por vazão natural aquela que ocorreria numa dada seção do rio, se não houvessem ações antrópicas na sua bacia contribuinte, tais como: regularizações através de reservatórios, desvios, evaporação nos reservatórios e usos consuntivos da água (irrigação e abastecimento urbano rural e industrial).

Para melhor caracterizar o problema objeto deste estudo apresenta-se, a título de ilustração, o comportamento das vazões naturais médias mensais no período entre os anos de 1931 a 2011, para o reservatório de Itumbiara, que está localizado na divisa dos estados de Minas Gerais e Goiás (Figura 22). Na Figura 23 é apresentada uma análise estatística dos dados das vazões naturais, mês a mês, no período coberto. Verifica-se que o mês de fevereiro é o que apresenta as maiores vazões naturais e também as maiores variações em seus valores. Estes dados de vazões naturais constituem a principal entrada da metodologia empregada.

A potência gerada por cada central, para cada intervalo de tempo, é determinada pela equação 4.2, onde a função de produtividade foi aproximada por um polinômio de quinto grau, em função do volume médio armazenado no reservatório para cada intervalo de tempo, cujos coeficientes se encontram apresentados na Tabela 5, da mesma forma que no item 6.1.1.

Os limites para os parâmetros operacionais de cada uma das centrais componentes do micro sistema em estudo, apresentados na Tabela 6, foram obtidos do Operador Nacional do Sistema Elétrico (ONS). A numeração indicadora correspondente a cada usina foi apresentada na figura 21.




FIGURA 22: Vazões naturais médias mensais em m^3/s no reservatório de Itumbiara-GO, no período entre os anos de 1931 e 2012 fonte: http://www.ons.org.br/operacao/vazoes_naturais.aspx




FIGURA 23: Boxplot mês a mês das vazões naturais médias mensais em m^3/s no reservatório de Itumbiara-GO, no período entre os anos de 1931 e 2012 fonte: http://www.ons.org.br/operacao/vazoes_naturais.aspx

TABELA 5: Coeficientes do polinômio para a função produtividade ξ_i .

Coeff	Usina				
	1	2	3	4	5
$a_0(\times 10^1)$	7.261600	5.774166	4.555294	7.985410	5.244398
$a_1(\times 10^5)$	6.84174	18.1900	34.9788	5.7208	3.1731
$a_2(\times 10^9)$	-7.87711	0.0	196.0	5.0	2.0
$a_3(\times 10^{13})$	9.11797	0.0	0.0	0.0	0.0
$a_4(\times 10^{17})$	-6.49561	0.0	0.0	0.0	0.0
$a_5(\times 10^{21})$	1.95365	0.0	0.0	0.0	0.0

TABELA 6: Limites para os parâmetros operacionais das cinco hidroelétricas e seus reservatórios.

Parâmetro	Usina				
	1	2	3	4	5
Min vol (hm ³)	2.412	974	470	4.669	4.573
Max vol (hm ³)	12.792	1.120	1.500	17.725	17.027
Max Power (MW)	510	408	375	1.192	2.280
Min flow (m ³ /s)	125	080	070	170	190
Max flow (m ³ /s)	510	675	570	1.048	3.222

6.2.1 Aplicação da Formulação Irrestrita a Múltiplos Reservatórios

A implementação foi realizada através do algoritmo NSGA-II padrão (DEB *et al.*, 2002). Experimentos iniciais indicaram a utilização de probabilidades de 85% para o operador de cruzamento e 35% para o de mutação, objetivando melhorar a exploração do domínio do problema. Foi empregado um operador de mutação por indivíduo com distribuição gaussiana. A probabilidade de cruzamento do operador utilizado é por par de indivíduos.

Os experimentos foram executados para dados de dois anos, o primeiro, um ano típico, de maio de 1976 a abril de 1977, aqui denominado de caso 1976-77, sendo fixados os volumes inicial e final em 95% do limite máximo. Para o segundo ano, menos chuvoso, de maio de 2000 a abril de 2001, aqui denominado de caso 2000-01 com os volumes inicial e final fixados em 85% do máximo.

Os resultados preliminares para o caso 1976-77 apresentaram um grande espalhamento. Como primeira tentativa de melhorá-los o limite de gerações foi estendido até 50.000, o que representou certa melhora. A Figura 24, apresenta os conjuntos de soluções eficientes para o caso 1976-77, observa-se que o espalhamento nos resultados se manteve. Objetivando melhora nos resultados foi tentado alterar a probabilidade de mutação para 50% e 65%, conduzindo os conjuntos eficientes a região entre o melhor e o pior

resultado obtido para a probabilidade de mutação de 35%, o que não nos permite afirmar que houve melhora com a alteração da probabilidade de mutação.




FIGURA 24: Resultados para o caso 1976-77, conjuntos eficientes de 30 rodadas, com 400 indivíduos e 50.000 gerações, para diferentes probabilidades de mutação, 35% em preto, 50% em azul, e 65% em verde. Em vermelho, está representado o resultado de uma única rodada, com a população inicial obtida da combinação dos conjuntos eficientes de rodadas com 400 indivíduos e 25.000 gerações.

Os resultados da otimização para o ano de condições pluviométricas menos favoráveis, caso 2000-01, ao final de um período mais seco do que o normal, foram mais consistentes e são apresentados na Figura 25. Como era esperado pelas condições operacionais eles foram inferiores aos do caso 1976-77, contudo, cobrindo uma faixa bem mais larga de valores dos objetivos, em especial aos relacionados a máxima mínima potência gerada.

Os resultados do algoritmo para os dois casos guardam uma clara diferença entre si, as soluções eficientes do primeiro caso apresentam grande espalhamento enquanto que no segundo caso o espalhamento é menor. Uma possível explicação para este fato pode ser encontrada na análise das variáveis de decisão para todo o conjunto das soluções eficientes.

No caso 1976-77, apesar das soluções eficientes serem originadas a partir de quatro diferentes experimentos, as variáveis de decisão, frações de volumes permitidos, se mostraram quase constantes para as duas maiores usinas, Emborcação e Itumbiara, ver Figura 26 e apresentaram pequena variação para a terceira maior usina, Nova Ponte. Significando que dois quintos das variáveis de decisão mantiveram seus valores praticamente constantes, enquanto que outro quinto experimentou pequenas variações ao longo de todo




FIGURA 25: Resultados para o caso 2000-01, em preto apresentam-se os conjuntos eficientes para 30 rodadas com 400 indivíduos e 50.000 gerações. Em vermelho, o conjunto eficiente para uma única rodada, com 400 indivíduos e 25.000 gerações, mas com a população inicial obtida da combinação destas soluções eficientes

o conjunto de soluções eficientes.

Para o caso 2000-01, as variáveis de decisão experimentaram variações mais significativas em todas as usinas exceto Itumbiara, a última a jusante na cascata e que recebe a afluência mais estabilizada, ver Figura 27. Neste caso, menos do que um quinto das variáveis de decisão mantém seu valor ainda fixo sobre todo o conjunto de soluções eficientes. Esta diferença de comportamento do algoritmo e a aparente insensibilidade às variações nas probabilidades de mutação leva-nos a apontar o operador de mutação como principal responsável pelo problema observado. No simples operador de mutação com distribuição gaussiana empregado, uma mutação corresponde a alterar cada variável do indivíduo. No caso 1976-77, muitas das variáveis devem permanecer aproximadamente constantes para que a solução seja candidata a pertencer ao conjunto de soluções eficientes, o que inviabiliza ao operador de mutação produzir indivíduos superiores. Ao passo que no caso 2000-01, onde um número muito menor de variáveis de decisão devem ficar aproximadamente constantes esta probabilidade do operador de mutação gerar indivíduos melhores é muito maior, levando assim a resultados mais consistentes.

Diante do observado com estes resultados, passou-se a adotar um operador de mutação que atuasse sobre variáveis do indivíduo, cujo desempenho pode ser avaliado em com-




FIGURA 26: Resultados caso 1976-77. Boxplot sobre o Conjunto Pareto das variáveis mesais de decisão (α) para cada central hidroelétrica.




FIGURA 27: Resultados caso 2000-01 . Boxplot sobre o Conjunto Pareto das variáveis mensais de decisão (α) para cada central hidroelétrica.

paração ao operador de mutação por indivíduo, até então empregado, na Figura (28).




FIGURA 28: Comparação do desempenho dos operadores de mutação por indivíduo, curvas em vermelho, e por variável, curvas em azul, aplicado ao sistema de cinco usinas para 400 indivíduos e 1500 gerações. Também em vermelho a curva de Pareto de referência descrita na Figura (24)

6.2.2 Análise de Sensibilidade

Definido o modelo com os operadores genéticos que se mostraram apropriados para o problema de otimização de sistemas de reservatórios, os primeiros ensaios computacionais foram realizados para determinar a sensibilidade da metodologia proposta à alteração dos parâmetros utilizados no algoritmo genético. Foram estudadas a influência da alteração do tamanho da população, das probabilidades de cruzamento e de mutação, do número máximo de gerações, além da variação do raio de mutação e do tamanho da extrapolação das extremidades do segmento linear que une os pais no cruzamento.

Testes iniciais do algoritmo mostram que, mesmo sem qualquer ajuste dos parâmetros, um esforço computacional em torno de seis milhões de chamadas da função objetivo, geram frentes de Pareto estáveis sem grandes dispersões. Dessa forma, este limite foi adotado na análise. Cada experimento consistiu de 10 execuções do algoritmo.

Foi adotado como critério de desempenho para os testes de análise de sensibilidade do algoritmo a melhor e pior curva de Pareto combinada das soluções eficientes de 10 execuções de cada conjunto de parâmetros do algoritmo genético multiobjetivo.

Tamanho da População

Realizaram-se experimentos com a população variando entre 600 e 1100 indivíduos, mantendo-se o esforço computacional constante; empregou-se uma probabilidade de mutação de 12,5%, de cruzamento de 85%, com o raio básico de mutação dividido por 6 e o segmento de cruzamento extrapolado em 100%. Os resultados obtidos para as curvas de Pareto aparecem na Figura 29.




FIGURA 29: Influência do tamanho da população na metodologia.

Para facilitar a visualização, são apresentados apenas os melhores e os piores resultados gerados por cada experimento. Os experimentos que utilizam os menores e maiores tamanhos de população (de 600 a 1100 indivíduos) apresentam resultados claramente inferiores aos demais. Em especial, as melhores e piores frentes de Pareto geradas com a população de 1100 indivíduos foram inferiores aos seus similares, tanto na amplitude quanto na dominância.

Os resultados obtidos para uma população de 600 indivíduos não superaram nenhum dos resultados dos demais experimentos, exceto no extremo de ótima potência média. Os melhores resultados foram os obtidos nos experimentos com população de 800 e 1000 indivíduos, não havendo característica que indicasse, visualmente, haver superioridade de um sobre o outro. Dessa forma, outro experimento foi realizado com uma população de 900 indivíduos, sem que esse indicasse vantagem marcante sobre os anteriores.

Probabilidade de Cruzamento

Foram avaliados valores de probabilidades de cruzamento de 80%, 85% e 90%, para diferentes tamanhos de população (de 600 a 1100 indivíduos). Os resultados obtidos para uma população de 1000 indivíduos com uma probabilidade de mutação de 10%, um raio de mutação dividido por 6 e extrapolação dos extremos do segmento linear que passa pelos pais no cruzamento de 80%, são mostrados na Figura 30. Da mesma forma que na Figura 29 apenas os melhores e piores resultados de cada experimento são exibidos. Observa-se que os melhores desempenhos são apresentados pelas probabilidades de cruzamento de 80% e 85%, exceto numa faixa próxima ao extremo de ótima potência média, onde os melhores resultados foram obtidos para uma probabilidade de mutação de 90%.




FIGURA 30: Influência da probabilidade de cruzamento com população de 1000 indivíduos, probabilidade de mutação de 10%, raio de mutação dividido por 6 e extrapolação dos extremos no cruzamento em 80%.

Probabilidade de Mutação

Para avaliar a influência da probabilidade de mutação, considerou-se os demais parâmetros do algoritmo genético fixos. Uma população de 800 e 1000 indivíduos, o esforço computacional constante, uma probabilidade de cruzamento de 85%, um raio básico de mutação dividido por 6 e o segmento de cruzamento extrapolado em 80%. Nos ensaios computacionais a probabilidade de mutação teve variação de valores de 10%, 12.5% e 15%.

A Figura 31 mostra a influência de diferentes valores de probabilidade de mutação sobre as curvas de Pareto para uma população de 800 indivíduos. Fica evidente a superi-

oridade dos resultados para o valor de probabilidade de 10%, exceto no final do segmento do extremo de máxima potência, onde a probabilidade de mutação de 15% mostrou-se superior.




FIGURA 31: Influência da probabilidade de mutação na metodologia para uma população de 800 indivíduos.

Fator K do Raio de Mutação

Foram utilizados os valores da constante K (Equação 5.4) de 1, 3, 6 e 9, no cálculo da amplitude das perturbações na mutação. A Figura 32 mostra a influência da variação deste parâmetro sobre as curvas de Pareto para uma população de 800 indivíduos. Observa-se dos testes realizados a superioridade do valor de K igual 6 com respeito aos outros valores.

Extrapolação dos extremos do segmento linear entre os pais no cruzamento

Foi estudada a influência no comportamento das soluções eficientes de diferentes valores no comprimento da extrapolção do segmento de reta que passa pelos pais no cruzamento (Equação 5.2). Os valores avaliados para a extrapolção do comprimento, além dos pais, foram de 20%, 40%, 60%, 80%, 100%, 120% e 140% da distância entre os pais.

A Figura 33 mostra, para uma população de 800 indivíduos, probabilidades de cruzamento de 85% e de mutação de 10%, a influência do valor das extrapolções no comportamento das curvas de Pareto. Os resultados mostram melhor desempenho numa faixa mais ampla de variação de ambos objetivos, para valores de 80 e 100% de extrapolção do segmento linear. Enquanto que para um valor de 140% de extrapolção ocorreu um desempenho mais significativo numa pequena faixa próxima ao extremo de máxima potência




FIGURA 32: Influência do fator K na amplitude de variação da mutação de uma população de 800 indivíduos na metodologia.

média.

6.2.2.1 Conclusões da Análise de Sensibilidade

A Figura 34 apresenta os melhores e piores resultados das três diferentes combinações de parâmetros, para o algoritmo genético multiobjetivo, que obtiveram melhor desempenho entre todas as combinações de parâmetros avaliadas nos testes de sensibilidade.

A primeira dessas combinações está definida para uma população de 800 indivíduos, com uma extrapolação de 100% dos extremos do segmento linear que une os indivíduos pais no cruzamento, 10% de mutação, 85% de probabilidades de cruzamento e um raio de mutação dividido por 6 (curva vermelha). A segunda combinação está definida para uma população de 800 indivíduos, uma extrapolação do segmento linear que une os pais no cruzamento de 80%, 10% de probabilidade de mutação, 85% de probabilidade de cruzamento e raio de mutação dividido por 6 (curva roxa). Finalmente, a terceira combinação está definida para uma população de 1000 indivíduos, probabilidades de cruzamento de 80%, 12,5% de probabilidade de mutação, 80% de extrapolação do segmento linear que une os pais no cruzamento e um raio de mutação dividido por 6 (curva verde).




FIGURA 33: Influência da extrapolação dos extremos do segmento linear que une os indivíduos pais no cruzamento.

Na seção de anexos são mostrados, na Figura 43, a melhor e pior combinação de 10 rodadas das curvas de Pareto para todos os conjuntos de parâmetros estudados.

Considerando os resultados da análise de sensibilidade, essas três combinações descritas acima serão empregadas nos estudos dos diferentes cenários.

6.3 Estudos de Cenários

Nesta seção são apresentados os resultados relativos à aplicação da metodologia, aqui desenvolvida, ao estudo da otimização da operação do subsistema de cinco reservatórios diante de quatro diferentes cenários:

- i. Cenário 1 - Considerações na Geração de Hidroeletricidade;
- ii. Cenário 2 - Considerações Socioambientais;
- iii. Cenário 3 - Considerações Sobre Segurança e Robustez Energéticas.
- iv. Cenário 4 - Otimização de longo prazo versus a otimização obtida pela combinação das soluções ótimas dos anos em separado.




FIGURA 34: Desempenho dos melhores e piores resultados para as três combinações de parâmetros mais eficientes nos testes de sensibilidade do algoritmo genético.

Para a otimização desses cenários serão utilizados os três grupos de parâmetros para algoritmo genético multiobjetivo definidos pelo análise de sensibilidade, conforme apresentado na Tabela 7.

TABELA 7: Conjunto de parâmetros do algoritmo genético definidos pela análise de sensibilidade.

Grupo	N_{ind}	p_{cross}	p_{mut}	K	extrapolação
Parâmetros 1	800	85%	10%	6	100%
Parâmetros 2	800	85%	10%	6	80%
Parâmetros 3	1000	80%	12,5%	6	80%

6.3.1 Cenário 1 - Considerações na Geração de Hidroeletricidade

Neste cenário é avaliado o desempenho da metodologia desenvolvida, empregando as três combinações de parâmetros obtidos na análise de sensibilidade, considerando-se os dois objetivos ligados à geração de hidroeletricidade utilizados. A Figura 35 apresenta as curvas de Pareto resultantes da combinação das melhores soluções eficientes de 10 execuções para cada conjunto de parâmetros do AG.

Na Figura 36 tem-se a curva de Pareto obtida pela combinação das soluções eficientes apresentadas na Figura 35. Esta curva de Pareto é composta pelas melhores curvas combinadas de soluções eficientes encontradas nas 10 execuções do algoritmo utilizando cada uma das combinações da Tabela 7.

A tomada de decisão pode ser efetuada considerando os preços relativos entre a energia firme e a secundária e o conjunto de soluções encontrado ao final da otimização. Estas representam relações de compromisso entre os dois objetivos, f_1 (maximização da potência média), que significa uma maior quantidade de energia a ser comercializada, mas distribuída de maneira não uniforme ao longo do ano e f_2 (maximização da menor potência produzida), que garantiria um maior valor de potência firme a ser negociado. Este valor de f_2 , escolhido pelo decisor, indicará o nível de potência complementar que será necessário considerar na decisão para a operação dos cinco reservatórios, visando a geração de energia elétrica.




FIGURA 35: Curvas de Pareto do desempenho elétrico do subsistema de cinco usinas resultantes da concatenação das soluções eficientes de 10 execuções do algoritmo, para cada uma das as três combinações de parâmetros definidas na análise de sensibilidade.

6.3.2 Cenário 2 - Considerações Socioambientais

Nesta seção são apresentados os resultados do estudo do segundo cenário, onde pretende-se garantir a navegabilidade de um trecho do Rio Araguari, entre os reservatórios das centrais hidroelétricas de Nova Ponte e de Miranda. Assim, além dos objetivos de




FIGURA 36: Curva de Pareto formada pela combinação de todas as soluções eficientes para 10 execuções do algoritmo para cada um dos três grupos de parâmetros de melhor desempenho na otimização do subsistema de cinco usinas (cada cor representa um conjunto de parâmetros do AG).

geração elétrica Equações (4.14) e (4.15), empregou-se um objetivo ligado à navegabilidade Equação (4.19). Tratou-se deste terceiro objetivo utilizando uma adaptação do método ϵ – *restrito* (CHANKONG; HAIMES, 1983). Com esta finalidade, foram fixados diferentes valores de vazão turbinada mínima para a central hidroelétrica de Nova Ponte, em um intervalo entre $125 \text{ m}^3/\text{s}$ e $275 \text{ m}^3/\text{s}$, procedimento este que conduz a uma representação bidimensional das três frentes de Pareto.

A Figura 37 mostra a influência destes diferentes valores impostos de vazão turbina mínima nas curvas de Pareto, do conjunto das cinco centrais hidroelétricas.

Como esperado, observa-se que, quando o valor fixado para a vazão turbinada mínima desta central é aumentado, pioram os valores de ambos os objetivos para o conjunto das cinco centrais.

Entretanto, a potência mínima gerada é muito menos dependente da variação da vazão turbinada mínima do que a potência média, quando o objetivo navegabilidade é considerado. Não obstante, o conflito entre o objetivo de mínima potência com o objetivo de navegabilidade é caracterizado, porque um certo nível de garantia de navegabilidade requer uma determinada vazão turbinada, enquanto que um valor de mínima potência pode ser obtido por diferentes vazões turbinadas com diferentes níveis do reservatório,

tornando esses objetivos diferentes.




FIGURA 37: Influência da navegabilidade sobre as curvas de Pareto do subsistema estudado, a curva em vermelho corresponde a uma vazão turbinada mínima de $275\text{m}^3/\text{s}$, a curva em laranja um valor de $250\text{m}^3/\text{s}$, a curva em roxo $225\text{m}^3/\text{s}$, em magenta $218,5\text{m}^3/\text{s}$, em azul $200\text{m}^3/\text{s}$, em ciano $187,5\text{m}^3/\text{s}$, em verde claro $175\text{m}^3/\text{s}$ e em verde escuro $125\text{m}^3/\text{s}$.

Uma outra utilidade identificada na análise desse cenário, é a possibilidade de avaliar o impacto nas perdas de receita com a energia elétrica produzida pelo conjunto das cinco usinas, quando se considera a navegabilidade. Para isso, foi proposto um modelo hipotético de mercado de energia, onde a receita produzida segue a equação:

$$R = (P_f \cdot f_2 + P_{ld} \cdot f_1) \Delta t \quad (6.2)$$

onde R é a receita total gerada pelo conjunto de hidroelétricas em (R\$), P_f é o preço da energia firme em (R\$/MWh), P_{ld} é o preço pago hipoteticamente pela energia média gerada, f_1 e f_2 são, respectivamente, a potência média gerada e a mínima potência gerada no ponto de operação considerado e Δt é o intervalo de tempo considerado em (h).

Tem-se, na Figura 38, uma previsão da receita que poderia ser obtida com a operação do subsistema, diante de diferentes valores de restrição para a navegabilidade do trecho considerado, onde foram arbitrados valores de 80,00 R\$/MWh para o P_{ld} e de 110,00 R\$/MWh para o P_f . Observa-se na figura, que o ponto de receita máxima ocorre próximo ao extremo da máxima energia assegurada, porém, a receita máxima não coincide exa-

tamente com o máximo da energia assegurada, e, a medida que o nível de garantia de navegabilidade cresce, este afastamento dos máximos também cresce.

Finalmente, na Figura 39 são apresentados os valores de máxima receita para a simulação do mercado de energia considerado. A análise desta figura permite avaliar a relação de compromisso entre a geração de energia e a garantia de navegabilidade. Verifica-se que uma variação na condição de navegabilidade de 125 m³/s para 225 m³/s pode ser obtida quase sem perda de receita, apenas 0,4% em relação a condição de operação, sem considerar a navegabilidade. Entretanto, uma mudança de 225 m³/s para 275 m³/s na condição de navegabilidade acarretaria uma redução de 2,5% na receita total. Isto mostra que a análise das relações de compromisso entre os objetivos define o custo da navegabilidade em termos do custo de oportunidade relacionado com um serviço negociável (a energia elétrica). Abordagens similares podem ser usadas para quantificar o custo de outros usos para a água dos reservatórios.




FIGURA 38: Influência da navegabilidade na curva de receita para o subsistema de cinco usinas.

6.3.3 Cenário 3 - Considerações Sobre Segurança e Robustez Energéticas

Um estudo de otimização da operação dos cinco reservatórios, quando as condições de armazenamento iniciais e finais são diferentes, é desenvolvido no cenário 3. Na Figura




FIGURA 39: Valor máximo de receita para cada condição de navegabilidade.

40 são apresentadas as melhores e piores curvas de Pareto, em 10 execuções do algoritmo, com os objetivos de Maximizar a Geração de Energia e Maximizar a Mínima Potência Gerada para diferentes valores de fração de volume inicial e finalizando com fração de volume de 95% do volume máximo. A curva azul representa uma fração inicial de 60% do volume máximo; a curva verde a fração inicial é de 70%; a vermelha a fração inicial é de 80%; a curva na cor ciano representa uma fração inicial de 90% do volume máximo e, por fim, a curva na cor roxa mostra uma fração de volumes inicial e final iguais a 95%. Os resultados indicam que quanto mais as frações de volume iniciais se diferenciam das finais piores são os resultados em termos de desempenho, porém, aumenta a amplitude em número de soluções do conjunto de soluções eficientes. Nestas condições de otimização ambas as funções objetivo são afetadas pela mudança na condição inicial da otimização.

Essa análise sugere que, se for possível prever a ocorrência futura de um ano de seca, provavelmente será preferível antecipar a entrada em operação de usinas térmicas, de forma a preservar a eficiência da geração hidroelétrica mesmo durante a seca. Tal recomendação implicaria, por exemplo, em uma conduta de planejamento bastante distinta da que foi adotada pela ONS em 2013 e 2014, ao deixar de acionar as centrais termoelétricas diante de uma expectativa de chuvas que não se realizou. Tal conduta ocasionou prejuízos econômicos e sociais em decorrência dos níveis críticos em que se encontram os reservatórios.




FIGURA 40: Resultados caso 1976-77. Influência nas curvas de Pareto para diferentes frações iniciais do volume máximo para cada reservatório do subsistema.

6.3.4 Cenário 4 - Otimização de longo prazo versus a otimização obtida pela combinação das soluções ótimas dos anos em separado

Nesta subseção foram comparados os resultados obtidos para o subsistema de usinas, considerando um período de otimização de 36 meses, com o Pareto obtido pela combinação das soluções ótimas de cada ano em separado. Para a otimização de cada ano do período em separado, a condição final de fração de volume de cada reservatório, ao final de cada ano, foi adotada como condição de fração inicial de volume para o próximo ano, dentro do período de otimização. Foram otimizados dois períodos, com duração de 36 meses, com início nos dois anos abordados anteriormente, um chuvoso, a partir de 1976, e outro seco, a partir de 2000.

A Figura 41 mostra as curvas de Pareto obtidas para o período de 1976 a 1978, tanto para o período de otimização de 36 meses, curva em azul, quanto para a combinação das soluções eficientes obtidas para cada ano em separado, curva em vermelho. Os parâmetros utilizados no algoritmo para esta otimização foram: 800 indivíduos, probabilidades de cruzamento e mutação de 85% e 10% respectivamente, raio de mutação dividido por 6 e uma extrapolação do segmento linear que une os pais no cruzamento de 100%.

Na Figura 42 são apresentadas as mesmas curvas para o período de 2000 à 2002. Foram

empregados os mesmos conjuntos de parâmetros para o algoritmo genético e legenda da figura anterior, para as curvas de Pareto deste período de otimização. Observa-se, em ambos os casos, que as curvas de Pareto obtidas para as otimizações de longo prazo geram resultados superiores aos da combinação de soluções eficientes para os três anos em separado. Contudo, no período com cenário mais seco, a curva de Pareto produzida pela combinação de soluções eficientes dos anos em separado apresentou-se mais estendida que a fornecida pela otimização de prazo mais longo.




FIGURA 41: Resultados caso 1976-77. Influência nas curvas de Pareto para dois diferentes períodos de otimização do subsistema de cinco reservatórios.

As aplicações apresentadas demonstram a aplicabilidade do algoritmo desenvolvido para a otimização de sistemas com múltiplos reservatórios e múltiplos usos da água.




FIGURA 42: Resultados caso 2000-2002. Influência nas curvas de Pareto para dois diferentes períodos de otimização do subsistema de cinco reservatórios.

7 *Contribuições da Tese e Trabalhos Futuros*

7.1 Conclusões

O presente trabalho apresenta uma adaptação de um clássico algoritmo evolutivo multiobjetivo para a otimização da operação de múltiplos reservatórios interligados e com múltiplos usos para a água armazenada. O estudo volta-se para objetivos ligados à geração de eletricidade, bem como às finalidades econômicas e sociais, como a navegabilidade de um trecho de rio.

O clássico algoritmo multiobjetivo *NSGA-II* (DEB *et al.*, 2002) foi utilizado como base. Foram introduzidas modificações nos operadores genéticos para atender às características específicas do problema. A principal modificação, contudo, e que trouxe o maior ganho na eficiência do algoritmo proposto, foi uma nova codificação das variáveis de decisão, tornando a metodologia irrestrita e limitada.

Num primeiro caso, foram aplicadas três diferentes formulações para manipular as restrições em um sistema de um único reservatório, num período de otimização de 12 meses. As duas primeiras formulações utilizam o volume mensal armazenado no reservatório como variável de decisão, já a terceira emprega como variável de decisão a fração de volume α (fração entre os volumes máximo e mínimo fisicamente viáveis).

A primeira formulação empregada, denominada Formulação Básica (5.2.1), utiliza como variável de decisão o volume do reservatório ao final de cada intervalo, permitindo-se uma variação entre 85% e 100% do volume máximo do reservatório. Os volumes inicial e final da otimização foram fixados em 95% do volume máximo do reservatório. Também foram consideradas outras restrições operacionais como as vazões turbinadas mínima e máxima e a potência gerada máxima (4.3.2.2). Empregando esta formulação, poucos experimentos produziram populações com indivíduos factíveis, gerando frentes de Pareto estreitas nos oito experimentos realizados (Figura 15).

A segunda formulação testada, denominada Redução do Domínio das Variáveis de Decisão (5.2.2), corresponde à imposição de um limite inferior variável para o volume do reservatório, intervalo a intervalo, baseado nas necessidades de recuperação do volume armazenado ao longo do período simulado, sendo as demais restrições as mesmas da formulação básica. Com esta formulação se obteve uma frente de Pareto completamente povoada, conforme mostrado na Figura 16, apresentando, entretanto, grande dispersão nos resultados entre as diferentes execuções.

A terceira formulação, denominada Formulação Irrestrita (5.2.3), emprega frações de volume como variáveis de decisão, que são obtidas considerando a conservação da massa e a máxima capacidade de recuperação do volume do reservatório num intervalo de tempo. Foram adotados os mesmos parâmetros de execução da segunda formulação. Desta forma, obteve-se uma frente de Pareto ampla e bem povoada a cada execução, como representado na Figura 17.

Na Figura 18 foram apresentadas todas as soluções eficientes e as frentes de Pareto combinadas para a segunda e terceira formulações. É evidente, desses experimentos, que a formulação irrestrita gera melhores resultados, produzindo em todos os experimentos frentes mais amplas, que se comparam, ou até mesmo superam, a frente de Pareto obtida pela combinação dos resultados da formulação da redução do domínio das variáveis de decisão.

Numa segunda fase, buscando demonstrar a capacidade da metodologia para tratar sistemas de maior complexidade, foram realizados experimentos com um sistema de cinco reservatórios com acoplamento hidráulico entre eles. Sobre esse sistema, em primeiro lugar, foi feita uma análise de sensibilidade da metodologia proposta à alteração dos parâmetros utilizados no algoritmo genético. Estabeleceu-se, baseado nos primeiros experimentos, que mesmo sem qualquer ajuste dos parâmetros, um esforço computacional, em torno de seis milhões de chamadas da função objetivo, gera frentes de Pareto estáveis sem grandes dispersões.

Em seguida, foram estudados quatro cenários para um ano tipicamente chuvoso e outro tipicamente seco. No primeiro cenário, foi realizada uma análise com objetivos ligados a geração hidroelétrica, considerando cada um dos três grupos de parâmetros alcançados na análise de sensibilidade.

Os resultados alcançados fornecem ao processo de tomada de decisão um conjunto de alternativas para o planejamento de operação do sistema de reservatórios, onde as implicações das relações de compromisso entre os objetivos de maximizar a potência média

e maximizar a menor potência gerada estão quantificados.

No segundo cenário, avalia-se a introdução de um terceiro objetivo, ligado a navegabilidade, em conjunto com os outros que vinham sendo analisados. Mostrou-se que, além da repercussão no desempenho elétrico do sistema de centrais, pode-se, até mesmo por meio de uma análise de custo de oportunidade, quantificar o custo para a navegabilidade pela perda de receita com a comercialização da energia produzida.

Análise de segurança e robustez energéticas foram abordadas no estudo do terceiro cenário, mostrando o comportamento das relações de compromisso entre os objetivos de desempenho elétricos considerados, quando a recuperação do volume armazenado é considerada. Os resultados encontrados mostram um comportamento eficiente da metodologia, sujeita às variações nas condições iniciais da otimização dos reservatórios.

Por fim, no quarto cenário, foi abordada uma comparação entre a otimização de mais longo prazo (36 meses) com a otimização de cada ano em separado do período otimizado. Os resultados mostram claramente que a otimização de longo prazo supera os resultados encontrados pela combinação das soluções eficientes para os anos em separado. Este comportamento foi observado nos dois períodos avaliados, anos mais secos e anos mais úmidos.

7.2 Contribuições

Os resultados obtidos no presente trabalho mostram que a nova codificação proposta, que transforma o problema de otimização de restrito para irrestrito e limitado, melhorou muito a eficiência do modelo em relação ao uso da variável de decisão original, o volume do reservatório.

A metodologia proposta permite o manuseio implícito da maioria das restrições envolvidas no problema de otimização de sistemas de múltiplos reservatórios e múltiplos usos da água, reduzindo o esforço computacional envolvido no tratamento das restrições.

Os casos de estudo ilustraram a utilidade das informações geradas para o processo de tomada de decisão no planejamento da operação destes sistemas. De igual forma, foi mostrado que é possível, até mesmo, usar os dados gerados para determinar o custo de qualquer novo uso da água em termos do custo de oportunidade, o que pode ser medido pelo retorno financeiro relacionado à venda de energia elétrica.

7.3 Sugestão para Trabalhos Futuros

A metodologia proposta mostra-se mais eficiente nos aspectos supracitados, mas apresenta uma dependência da variabilidade dos dados das vazões afluentes. Assim, aborda-se, em trabalho em elaboração pelo autor e colaboradores, tratamentos estatísticos dos dados históricos para melhorar a predição da afluência, transformando essa metodologia em um tratamento explícito para a incerteza nas afluências.

Outra vertente a ser abordada em trabalhos futuros, em fase inicial de desenvolvimento pelo autor, é a ampliação do número de objetivos, tratando, por exemplo, da garantia da navegabilidade de determinado trecho de rio ou da proteção contra enchentes a jusante de um reservatório como objetivos explícitos e não como foi tratado na seção 6.3.2 pelo método ϵ – *restrito*.

A consideração de novas fontes na matriz geradora como a eólica associada a hidroelétrica também ampliaria os horizontes do presente estudo.

Referências

- AHMED, Juran Ali; SARMA, Arup Kumar. Genetic algorithm for optimal operating policy of a multipurpose reservoir. *Water Resources Management*, v. 19, n. 2, p. 145–161, abr. 2005. Disponível em: <<http://dx.doi.org/10.1007/s11269-005-2704-7>>.
- AMORIM, Elizete de Andrade. *Fluxo de Potência Ótimo em Sistemas Multimercados Através de um Algoritmo Evolutivo Multiobjetivo*. 2006. Tese (Doutorado) — Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2006.
- ARROYO, José Elias Claudio. *Heurísticas e Metaheurísticas para Otimização Combinatória Multiobjetivo*. 2002. Tese (Doutorado) — Universidade Estadual de Campinas - UNICAMP, 2002.
- BARROS, M.T.L.; ROS, D.A.; LOPES, J.E.G. Objective functions for hydropower system operation. In: . Williamsburg, VA, United states: [s.n.], 2005. p. 1205 – 1215. Energy demand;Energy production;Hydropower operating systems;Non-linear methods;.
- BARROS, M. T. L.; TSAI, F. T-C.; YANG, S.; LOPES, J. E. G.; YEH, J. W-G. Optimization of large-scale hydropower system operations. *Journal of Water Resources Planning and Management*, v. 129, n. 3, p. 178–188, May/June 2003.
- BEBERT, Rampazzo Priscila Cristina. *Planejamento Hidrelétrico: Otimização Multiobjetivo e Abordagens Evolutivas*. 2012. Tese (Doutorado) — Universidade Estadual de campinas, 2012.
- BRANDÃO, João Luiz Boccia. *Modelo para Operação de Sistemas de Reservatórios com Usos Múltiplos*. 2004. Tese (Doutorado) — Universidade de São Paulo, 2004.
- CASTRO, Leandro Nunes de. Fundamentals of natural computing: an overview. *Physics of Life Reviews*, v. 4, p. 1–36, 2007.
- CHANG, Jian xia; BAI, Tao; HUANG, Qiang; YANG, Da wen. Optimization of water resources utilization by pso-ga. *Water Resour Manage*, v. 27, p. 3525–3540, 2013.
- CHANKONG, V.; HAIMES, Y. Y. *Multiobjective Decision Making: Theory and Methodology*. [S.l.]: Elsevier, 1983.
- CHEN, L.; CHANG, F. J. Applying a real-coded multi-population genetic algorithm to multi-reservoir operation. *Hydrological Processes*, v. 21, p. 688–698, 2007.
- CHENG, Chun-Tian; WANG, Wen-Chuan; XU, Dong-Mei; CHAU, K. Optimizing hydropower reservoir operation using hybrid genetic algorithm and chaos. *Water Resources Management*, v. 22, n. 7, p. 895–909, jul. 2008. Disponível em: <<http://dx.doi.org/10.1007/s11269-007-9200-1>>.

- CHIU, Yu-Chen; CHANG, Li-Chiu; CHANG, Fi-John. Using a hybrid genetic algorithm-simulated annealing algorithm for fuzzy programming of reservoir operation. *Hydrological Processes*, John Wiley & Sons, Ltd., v. 21, n. 23, p. 3162–3172, 2007. ISSN 1099-1085. Disponível em: <<http://dx.doi.org/10.1002/hyp.6539>>.
- CICOGNA, Marcelo Augusto. *Sistema de Suporte à Decisão para o Planejamento da Operação de Sistemas de Energia Elétrica*. 2003. Tese (Doutorado) — Universidade Estadual de Campinas - UNICAMP, 2003.
- COELLO, C. A. Coello; MAMONT, G. B.; VELDHUIZEN, D. A. V. *Evolutionary Algorithms for Solving Multi-Objective Problems*. 2^a. ed. [S.l.]: Springer-Verlag, 2007.
- CRUZ, André Rodrigues da. *Uma Metodologia Multiobjetivo para o Controle de Epidemias através de Vacinação Impulsiva via Algoritmo Genético com Operador de Busca Local Baseado em Aproximação Quadrática Convexa e Validação Estocástica*. 2011. Dissertação (Mestrado) — Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, 2011.
- DARWIN, Charles. *The variation of animals and plants under domestication*. [S.l.: s.n.], 1868.
- DEB, Kalyanmoy. An Efficient Constraint Handling Method for Genetic Algorithms. *Computer Methods in Applied Mechanics and Engineering*, v. 186, n. 2/4, p. 311–338, 2000.
- _____. *Multi-Objective Optimization using Evolutionary Algorithms*. Chichester, UK: John Wiley & Sons, 2001. ISBN 0-471-87339-X.
- _____. *Multi-Objective Optimazation Using Evolutionary Algorithms*. [S.l.]: John Wiley & Sons, 2009. 515p. p.
- _____. *Multi-Objective Optimazation Using Evolutionary Algotithms: An Introduction*. [S.l.], 2011.
- DEB, Kalyanmoy; AGRAWAL, Ram Bhushan. Simulated binary crossover for continuous search space. *omplex Systems*, v. 9, n. 2, p. 115–148, 1995.
- DEB, Kalyanmoy; AGRAWAL, Samir; PRATAB, Amrit; MEYARIVAN, T. A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II. In: SCHOENAUER, Marc; DEB, Kalyanmoy; RUDOLPH, Günter; YAO, Xin; LUTTON, Evelyne; MERELO, J. J.; SCHWEFEL, Hans-Paul (Ed.). *Proceedings of the Parallel Problem Solving from Nature VI Conference*. Paris, France: Springer. Lecture Notes in Computer Science No. 1917, 2000. p. 849–858. Disponível em: <citeseer.ist.psu.edu/article/deb00fast.html>.
- DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *Evolutionary Computation, IEEE Transactions on*, v. 6, n. 2, p. 182–197, 2002. ISSN 1089-778X.
- ENCINA, Anastacio Sebastián Arce. *Despacho Ótimo de Unidades Geradoras em Sistemas Hidrelétricos Via Heurística Baseada em Relaxação Lagrangeana e Programação Dinâmica*. 2006. Tese (Doutorado) — Universidade Estadual de Campinas, 2006.

- EPE. *Balanço Energético Nacional 2012: Ano Base 2011*. [S.l.]: Empresa de Pesquisa Energética – EPE, 2012. 282 p. p.
- _____. *Balanço Energético Nacional 2013: Ano Base 2012*. [S.l.]: Empresa de Pesquisa Energética – EPE, 2013.
- ESAT, V.; HALL, M. J. Water resources system optimization using genetic algorithms. In: *Proceedings of first international conference on hydroinformatics*. [S.l.: s.n.], 1994. p. 225–231.
- FILHO, Donato da Silva. *Dimensionamento de Usinas Hidroelétricas Através de Técnicas de Otimização Evolutiva*. 2003. Tese (Doutorado) — Escola de Engenharia de São Carlos da Universidade de São Paulo, 2003.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. [S.l.]: Addison-Wesley, 1989.
- HAKIMI-ASIABAR, Mehrdad; GHODSYPOUR, Seyyed Hassan; KERACHIAN, Reza. Multi-objective genetic local search algorithm using kohonen's neural map. *Computers & Industrial Engineering*, v. 56, p. 1566–1576, 2009.
- _____. Deriving operating policies for multi-objective reservoir systems: Application of self-learning genetic algorithm. *Applied Soft Computing*, v. 10, n. 4, p. 1151–1163, 2010. ISSN 1568-4946. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494609001392>>.
- HANSEN, P.; MLADENIVIC, N. Variable neighborhood search: Principles and applications. *European Journal of Operational Research*, v. 130, p. 449–467, 2001.
- HORN, J. Handbook of evolutionary computation. In: _____. [S.l.]: New York and Bristol: IOP Publishing and Oxford University Press,, 1997. cap. Multicriterion Decision Making., p. pp. F1.9:1– F1.9:15.
- KIM, Taesoon. *Multireservoir System OPtimization Using Multi-Objective Genetic Algorithms*. 2005. Tese (Doutorado) — The Graduate School Yonsei University Department of Civil Engineering, 2005.
- KNOWLES, Joshua D.; CORNE, David; DEB, Kalyanmoy. *Multiobjective Problem Solving from Nature: From Concepts to Applications*. first. [S.l.]: Springer - Verlag, 2007.
- KO, S. K.; FONTANE, D. G.; LABADIE, J. W. Multiobjective optimization of reservoir systems operation. *Water Resour Bull*, v. 28, p. 111–127, 1992.
- LABADIE, John W. Optimal operation of multireservoir systems: State-of-the-art review. *Journal of Water Resources Planning and Management*, v. 130, n. 2, p. 93–111, March 2004. Disponível em: <[http://dx.doi.org/10.1061/\(ASCE\)0733-9496\(2004\)130:2\(93\)](http://dx.doi.org/10.1061/(ASCE)0733-9496(2004)130:2(93))>.
- LARSON, R. E. *State Increment Dynamic Programming*. [S.l.]: Elsevier, 1968.

- LIMA, Henrique Vieira Costa; LANNA, Antônio Eduardo Leão. Modelos para a operação de sistemas de reservatórios: Atualização do estado da arte. *Revista Brasileira de Recursos Hídricos*, v. 10, p. 5–22, 2005.
- LOPES, João Eduardo Golçalves. *Modelo de Planejamento da Operação de Sistemas Hidrotérmicos de produção de Energia Elétrica*. 2007. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo, 2007.
- MURRAY, D. M.; YAKOWITZ, S. Constrained differential dynamic programming and its application to multireservoir control. *Water Resour Res.*, v. 15(5), p. 1017–1027, 1979.
- RANI, Deepti; MOREIRA, Maria Madalena. Simulation-optimization modeling: A survey and potential application in reservoir systems operation. *Water Resour Manage*, v. 24, p. 1107–1138, 2010.
- REIS, Lineu Belico dos. *Geração de Energia Elétrica*. 2^a. ed. [S.l.: s.n.], 2011.
- SCOLA, Luís Antônio; NETO, Oriane Magela; TAKAHASHI, Ricardo Hiroshi Caldeira; CERQUEIRA, Sérgio Augusto Araujo da Gama. Multi-objective optimal reservoir operation. In: *Proceedings of the 2010 IEEE World Congress on Computational Intelligence*. [S.l.: s.n.], 2010.
- SHARIF, Mohd; WARDLAW, Robin. Multireservoir systems optimization using genetic algorithms: Case study. *Journal of Computing in Civil Engineering*, v. 14, p. 255–263, 2000.
- SHARMA, V.; JHAB, R.; NARESH, R. Optimal multi-reservoir network control by two-phase neural network. *Electric Power Systems Research*, v. 68, p. 221–228, 2004.
- SIMONOVIC, S. P. *Managing Water Resources - Methods and Tools for a Systems Approach*. [S.l.]: UNESCO London, 2009. 640p. p.
- SRINIVAS, N.; DEB, K. Multiobjective optimization using nondominated sorting in genetic algorithms. *Evolutionary Computation*, v. 2(3), p. 221–248, 1994.
- TAKAHASHI, Ricardo Hiroshi Caldeira. Otimização escalar e vetorial. Disponível na página <http://www.mat.ufmg.br/taka/>. 2007.
- WARDLAW, Robin; SHARIF, Mohd. Evaluation of genetic algorithm for optimal reservoir system operation. *Journal of water resources planning and management*, v. 125, p. 25–33, 1999.
- WURBS, R. A. Reservoir-system simulation and optimization models. *Journal of Water Resources Planning and Management -ASCE*, v. 119(4), p. 455–472, 1993.
- YEH, William W-G. Reservoir management and operations models: A state-of-the-art review. *Water Resour. Res.*, American Geophysical Union, v. 21, n. 12, p. 1797–1818, 1985. Disponível em: <<http://dx.doi.org/10.1029/WR021i012p01797>>.
- YOUNG, G. K. Finding reservoir operating rules. *Journal of the Hydraulics Division*, v. 93(HY6), p. 297–321, 1967.

ZITZLER, Eckart. *Evolutionary Algorithms for Multiobjective Optimization: Methods and Applications*. 1999. Tese (Doutorado) — ETH Zurich, Switzerland, 1999.

Apêndices

Análise Sensibilidade




FIGURA 43: Estudo de sensibilidade aos parâmetros do algoritmo genético, conjunto dos melhores e piores resultados encontrados em 10 execuções, variando-se todos os parâmetros.

- + 1000ind-Pmut=10%-Pcross=80%- K=6-extr=80%-melhor
- o 1000ind-Pmut=10%-Pcross=80%- K=6-extr=80%-pior
- + 1000ind-Pmut=10%-Pcross=85%- K=6-extr=80%-melhor
- o 1000ind-Pmut=10%-Pcross=85%- K=6-extr=80%-pior
- + 1000ind-Pmut=10%-Pcross=90%- K=6-extr=80%-melhor
- o 1000ind-Pmut=10%-Pcross=90%- K=6-extr=80%-pior
- + 1000ind-Pmut=12,5%-Pcross=80%- K=6-extr=80%-melhor
- o 1000ind-Pmut=12,5%-Pcross=80%- K=6-extr=80%-pior
- + 1000ind-Pmut=12,5%-Pcross=85%- K=6-extr=80%-melhor
- o 1000ind-Pmut=12,5%-Pcross=85%- K=6-extr=80%-pior
- + 1000ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-melhor
- o 1000ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-pior
- + 1000ind-Pmut=12,5%-Pcross=90%- K=6-extr=80%-melhor
- o 1000ind-Pmut=12,5%-Pcross=90%- K=6-extr=80%-pior
- + 1000ind-Pmut=15%-Pcross=80%- K=6-extr=80%-melhor
- o 1000ind-Pmut=15%-Pcross=80%- K=6-extr=80%-pior
- + 1000ind-Pmut=15%-Pcross=85%- K=6-extr=80%-melhor
- o 1000ind-Pmut=15%-Pcross=85%- K=6-extr=80%-pior
- + 1000ind-Pmut=15%-Pcross=90%- K=6-extr=80%-melhor
- o 1000ind-Pmut=15%-Pcross=90%- K=6-extr=80%-pior
- + 1100ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-melhor
- o 1100ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-pior
- + 600ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-melhor
- o 600ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-pior
- + 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-melhor
- o 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-pior
- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=20%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=20%-pior

FIGURA 44: Parte A - Legenda do estudo de sensibilidade aos parâmetros do algoritmo genético, conjunto dos melhores e piores resultados encontrados em 10 execuções, variando-se todos os parâmetros.

- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=40%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=40%-pior
- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=60%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=60%-pior
- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=80%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=80%-pior
- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=100%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=100%-pior
- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=120%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=120%-pior
- + 800ind-Pmut=10%-Pcross=85%- K=6-extr=140%-melhor
- o 800ind-Pmut=10%-Pcross=85%- K=6-extr=140%-pior
- + 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=140%-melhor
- o 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=140%-pior
- + 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=60%-melhor
- o 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=60%-pior
- + 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=80%-melhor
- o 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=80%-pior
- + 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-melhor
- o 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=100%-pior
- + 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=120%-melhor
- o 800ind-Pmut=12,5%-Pcross=85%- K=6-extr=120%-pior

FIGURA 45: Parte B - Legenda do estudo de sensibilidade aos parâmetros do algoritmo genético, conjunto dos melhores e piores resultados encontrados em 10 execuções, variando-se todos os parâmetros.




FIGURA 46: Esquema das usinas hidroelétricas brasileiras componentes do SIN
 fonte: <http://www.ons.org.br>