

ESTE EXEMPLAR CORRESPONDE A REDAÇÃO FINAL DA
TESE DEFENDIDA POR Jéssica Pillon Torralba
Fernandes..... E APROVADA
PELA COMISSÃO JULGADORA EM 02 / 02 / 2011

Osvaldo L. B. C.
ORIENTADOR

**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
COMISSÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

Jéssica Pillon Torralba Fernandes

**Pré-Despacho de Usinas Hidrelétricas:
Implementação com Algoritmos Genéticos**

Campinas , 2011

10/2011

Jéssica Pillon Torralba Fernandes

Pré-Despacho de Usinas Hidrelétricas:

Implementação com Algoritmos Genéticos

Dissertação apresentada ao Curso de Mestrado da Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas, como requisito para a obtenção do título de Mestre em Planejamento de Sistemas Energéticos.

Orientador: Prof. Dr. Paulo de Barros Correia

Campinas

2011

i

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

F391p Fernandes, Jéssica Pillon Torralba
Despacho de Usinas Hidrelétricas: Implementa-
ção com Algoritmos Genéticos / Jéssica Pillon Tor-
ralba Fernandes – Campinas, SP: [s.n.], 2011.

Orientador: Paulo de Barros Correia.
Dissertação de Mestrado – Universidade Estadual
de Campinas, Faculdade de Engenharia Mecânica.

1. Algoritmos genéticos. 2. Otimização mate-
mática. 3. Programação linear. 4. Programação não-
linear. 5. Usinas hidrelétricas. I. Correia, Paulo de
Barros. II. Universidade Estadual de Campinas. Fa-
culdade de Engenharia Mecânica. III. Título.

Título em Inglês:	Dispatch Hydroelectric Power Plants: Implementation with Genetic Algo- rithms
Palavras-Chave em Inglês:	Genetic algorithms; Mathematical opti- mization; Linear programming; Nonli- near programming; Hydroelectric.
Área de Concentração:	
Titulação:	Mestre em Planejamento de Sistemas Energéticos
Banca Examinadora:	Joaquim Eugênio Abel Seabra e Taka- aki Ohishi.
Data da Defesa:	02/02/2011
Programa de Pós-Graduação:	Planejamento de Sistemas Energéticos

**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
COMISSÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
ENERGIA**

DISSERTAÇÃO DE MESTRADO

**Pré-Despacho de Usinas Hidrelétricas:
Implementação com Algoritmos Genéticos**


Autor: Jéssica Pillon Torralba Fernandes

Orientador: Prof. Dr. Paulo de Barros Correia


A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:



Prof. Dr. Paulo de Barros Correia, Presidente
Universidade Estadual de Campinas



Prof. Dr. Joaquim Eugênio Abel Seabra
Universidade Estadual de Campinas - UNICAMP



Prof. Dr. Takaaki Ohishi
Universidade Estadual de Campinas - UNICAMP

Campinas, 2 de fevereiro de 2011

Aos meus pais
Roberto e Elaine,
e ao meu irmão
Pedro Paulo
com muito amor e carinho.

AGRADECIMENTOS

Este trabalho não poderia ser terminado sem a ajuda de diversas pessoas às quais presto minha homenagem.

Agradeço, primeiramente, a Deus por me guiar em todos os caminhos da minha vida.

Aos meus pais, pela formação sólida que me forneceram durante toda a minha vida, pelo apoio e pelo incentivo.

Ao professor Paulo de Barros Correia pela sábia orientação e ajuda.

Aos professores Joaquim Seabra e Takaaki Ohishi pelas contribuições e sugestões feitas durante o exame de qualificação.

Ao Glauber pela sua importante colaboração em todas as etapas do meu mestrado, pois sem a sua ajuda esta dissertação não estaria pronta.

Aos meus avós Mariza e Walter pelo carinho, amor e apoio.

Aos meus colegas da sala 301, Alaíse, Bruna, Débora, Elisa, Glauber, Laura e Natália, que me deram força e alegria durante o mestrado.

Ao pessoal do Departamento de Energia;

As minhas amigas Giselle, Mariana e Viviane, que mesmo distantes, sempre estiveram ao meu lado me dando apoio, amor e incentivo.

Ao Daniel por entender a minha ausência, pela sua amizade e amor demonstrados durante a elaboração deste.

*”Não basta ensinar ao homem uma especialidade porque se tornará assim uma máquina utilizável e não uma personalidade. É necessário que adquira um sentimento, um senso prático daquilo que vale a pena ser empreendido, daquilo que é belo, do que é moralmente correto.” **Albert Einstein***

RESUMO

Esta dissertação de mestrado tem por objetivo apresentar e implementar um modelo de otimização da operação diária das usinas hidrelétricas do Médio São Francisco. O estudo considera oito usinas do sistema - Sobradinho, Luiz Gonzaga, Apolônio Sales, Paulo Afonso I, II, III e IV e Xingó - pertencentes à Companhia Hidro Elétrica do São Francisco. Seu objetivo é maximizar a eficiência de geração das usinas e minimizar o número de partidas e paradas de suas unidades geradoras, simultaneamente. A técnica de resolução é feita em duas etapas, sendo que a Etapa 1 determina quanto cada usina deve gerar a cada intervalo de tempo, e a Etapa 2 determina o número de unidades geradoras em operação e a carga de uma usina específica. A formulação matemática do problema proposto é de natureza não linear inteira mista e, para solucionar o modelo foram utilizadas técnicas de Computação evolutiva, em específico os Algoritmos genéticos, e de Programação linear. Esta metodologia foi desenvolvida com dois programas computacionais, ambos comerciais sendo um *software* com linguagem de programação de quarta geração. Um dos programas foi utilizado para a interface, enquanto no de quarta geração, o modelo de otimização foi implementado. A solução obtida aumenta a eficiência em relação ao despacho atual e em relação as restrições operativas usuais. A aplicabilidade deste modelo pode ser utilizada na otimização de outras usinas em cascata.

Palavras-Chave: Algoritmos genéticos; Otimização matemática; Programação linear; Programação não-linear; Usinas hidrelétricas.

ABSTRACT

This dissertation aims to presents and implement an optimization model for daily operation of Middle São Francisco River hydroelectric system. The study considers eight power plants – Sobradinho, Luiz Gonzaga, Apolônio Sales, Paulo Afonso I, II, III, IV e Xingó – witch belongs to the São Francisco Hydroelectric Company. Its objective is to maximize the power plant efficiency and, simultaneously, to minimize the number of startups and shutdowns of generating units. The technique of resolution is made in two steps: Step 1 determines the load allocated to each power plant at each hour; Step 2 defines the number of generating units in operation and the load of particular power plant. The mathematical formulation is non-linear mixed integer programs and solved with a Genetic Algorithm (GA) approach, and Linear Programming . This model was implemented with two computation programs, One a commercial optimization solver, and a in house GA solver coded with a programming language of fourth generation. One of the programs was used to interface, while the fourth generation, the optimization model was implemented. This solution increases efficiency in relation to the actual dispatch and for the usual operational restrictions. The applicability of this model can be used for the optimization of other plants in cascade.

Keywords: Genetic algorithms; Mathematical optimization; Linear programming; Nonlinear programming; Hydroelectric.

LISTA DE FIGURAS

1.1	Evolução da demanda total de energia hidroelétrica no Brasil, 1970-2030.	2
2.1	Corte longitudinal de uma UHE com os seus principais elementos físicos.	7
2.2	Cascata de UHEs do Rio São Francisco.	8
2.3	Exemplo de uma Curva de Carga diária de Sobradinho.	12
2.4	Curva Colina de uma UG em função da altura de queda da potência.	13
2.5	Curva Colina de uma UG em função da altura de queda e da vazão turbinada.	14
2.6	Estrutura básica de um sistema hidrotérmico.	16
2.7	Etapas do Planejamento de Operação.	17
2.8	Sistema do Médio São Francisco com as UHEs nele localizadas.	24
2.9	Esquema do problema de otimização na Etapa 1.	27
3.1	Diagrama da estrutura básica dos algoritmos da computação evolutiva.	31
3.2	Fluxo da implementação do AG.	37
3.3	Exemplo de <i>Roulette Wheel</i> com 5 indivíduos representados pela codificação binária juntamente com seus valores da função de aptidão.	46
3.4	Situação antes do <i>ranking</i> , ou seja, gráfico do <i>fitness</i>	47
3.5	Situação depois do <i>ranking</i> , ou seja, gráfico do número de ordem.	47
3.6	Exemplo de cruzamento com 1 ponto, aplicado à codificação binária.	49
3.7	Exemplo de cruzamento com 2 pontos, aplicado à codificação binária.	50
4.1	Exemplo que ilustra opções de compra de carro.	59
4.2	Dominância de Pareto no espaço objetivo Ω	60
4.3	Fronteira de Pareto.	61
5.1	Cascata de UHEs do Rio São Francisco.	67
5.2	Esquema de resolução do problema proposto.	72
6.1	Pontos de eficiência para uma altura de queda fixa	81
6.2	Aproximação por MQM: Pontos y_i e suas aproximações $\hat{y}_i$	82
6.3	Aproximações de polinômios de grau 4 por MQM e MQM ponderados	85

6.4	Esquema de resolução do modelo matemático	87
6.5	Interface da planilha de estudo de caso	88
6.6	Mensagem para aguardar a execução	89
6.7	Curvas de eficiência das UGs da UHE Sobradinho, medidas após quase 30 anos de instalação	91
6.8	Curva de eficiência da UG 1 da UHE Sobradinho	92
6.9	Curva de eficiência da UG 2 da UHE Sobradinho	92
6.10	Curva de eficiência da UG 3 da UHE Sobradinho	93
6.11	Curva de eficiência da UG 5 da UHE Sobradinho	93
6.12	Curva de eficiência da UG 6 da UHE Sobradinho	94
6.13	Transposição dos dados de eficiência da UG 4	96
6.14	Ajuste polinomial feito para a UG4 da UHE Sobradinho	96
6.15	Curva de eficiência de Paulo Afonso 4 de acordo com os dados coletados.	97
6.16	Curva de eficiência estimada com ajuste polinomial feito para a UG 1 da UHE Paulo Afonso IV	98
6.17	Curva de eficiência estimada com ajuste polinomial feito para a UG 2 da UHE Paulo Afonso IV	99
6.18	Curva de eficiência estimada com ajuste polinomial feito para a UG 3 da UHE Paulo Afonso IV	99
6.19	Curva de eficiência estimada com ajuste polinomial feito para a UG 4 da UHE Paulo Afonso IV	100
6.20	Curva de eficiência estimada com ajuste polinomial feito para a UG 5 da UHE Paulo Afonso IV	100
6.21	Curva de eficiência estimada com ajuste polinomial feito para a UG 6 da UHE Paulo Afonso IV	101
6.22	Curva gerada entre as curvas das UGs 3 e 2	101
6.23	Curva gerada entre as curvas das UGs 6 e 5	102
6.24	Curva gerada entre as curvas das UGs 6 e 2	102
6.25	Curva gerada entre as curvas das UGs 1 e 3	103
6.26	Curva gerada entre as curvas das UGs 2 e 1	103
6.27	Curva gerada entre as curvas das UGs 4 e 3	104

6.28	Curvas de eficiência de PA IV supostamente medidas depois de alguns anos de funcionamento.	104
7.1	Geração total da cascata e das UHEs	106
7.2	Reservatório da UHE Paulo Afonso IV	107
7.3	Reservatório da UHE Luiz Gonzaga	107
7.4	Reservatório da UHE Xingó	108
7.5	Soluções não dominadas para a UHE de Sobradinho	111
7.6	Soluções não dominadas para a UHE de Paulo Afonso IV	113
7.7	Geração e Turbinagem para USB	115
7.8	Geração e Turbinagem para USQ	115
7.9	Interface da Planilha Balanço Hidráulico	116
7.10	Interface da Planilha Tabelas	117

LISTA DE TABELAS

6.1	Curva de carga da cascata	86
6.2	Dados de Usinas	86
6.3	Condições de Contorno	86
6.4	Máquinas despachadas	87
6.5	Dados de eficiência da Usina de Sobradinho	91
6.6	Dados de eficiência da UG 4	95
6.7	Coeficientes dos ajustes polinomiais da UHE de Sobradinho	97
6.8	Coeficientes das UGs da UHE de Paulo Afonso IV	105
7.1	Resultados da otimização da Fase 1 do algoritmo para USB - demanda 519,6 MW . . .	109
7.2	Resultados da otimização da Fase 1 do algoritmo para USQ - demanda 1059,3 MW . .	110
7.3	Solução encontrada com menor número de partidas e paradas UHE Sobradinho	111
7.4	Solução encontrada com maior número de partidas e paradas UHE Sobradinho	112
7.5	Solução encontrada com menor número de partidas e paradas UHE Paulo Afonso IV .	113
7.6	Solução encontrada com maior número de partidas e paradas UHE Paulo Afonso IV . .	114

LISTA DE ALGORITMOS

4.1	Pseudo-código do SPEA	64
-----	---------------------------------	----

LISTA DE SIGLAS

AE	Algoritmos Evolutivos
AG	Algoritmo Genético
ANEEL	Agência Nacional de Energia Elétrica
CE	Computação Evolutiva
CHESF	Companhia Hidro Elétrica do São Francisco
DOC	Despacho Ótimo de Carga
EPE	Empresa de Pesquisa Energética
MME	Ministério de Minas e Energia
MQM	Método dos Quadrados Mínimos
ONS	Operador Nacional do Sistema Elétrico
PCH	Pequenas Centrais Hidrelétricas
PL	Programação Linear
SPEA	<i>Strengh Pareto Evolutionary Algorithm</i>
UAS	Usina Hidrelétrica Apolônio Sales (Moxotó)
UG	Unidade Geradora
UHE	Usina Hidrelétrica
ULG	Usina Hidrelétrica Luiz Gonzaga (Itaparica)
UPA	Conjunto das usinas hidrelétricas Paulo Afonso I,II e III
USB	Usina Hidrelétrica Sobradinho
USD	Usina Hidrelétrica Paulo Afonso II
USQ	Usina Hidrelétrica Paulo Afonso IV
USU	Usina Hidrelétrica Paulo Afonso I
UXG	Usina Hidrelétrica Xingó
4GLS	Linguagem de programação de quarta geração

LISTA DE SÍMBOLOS

d^j	Demanda das quatro usinas de UHE no período j	[MW]
$\overline{G}$	Geração das UHEs UPA e UAS	MW
h_m	Nível a montante da usina i	[m]
h_t	Nível a jusante da usina i	[m]
h_h	Perda por elevação do canal de fuga	[m]
i	Índice da usina	
j	Índice do período de tempo	
k	Índice da UG	
km	Quilômetro	[m ²]
kW	Kilowatt	
MW	Megawatt	
n_i	Número de UG em uma UHE i	
p_i^j	Potência gerada pela usina i no período j	[MW]
$p_{i,k}^j$	Potência gerada pela UG k da usina i período j	[MW]
$p_{i,k}^{j,min}$	Potência mínima da UG k da usina i período j	[MW]
$p_{i,k}^{j,max}$	Potência máxima da UG k da usina i período j	[MW]
Q_i	Vazão média que a usina i deve manter ao longo do dia	[m ³ /s]
q_i^j	Vazão turbinada pela usina i no período j	[m ³ /s]
UHE	Conjunto das usinas USB, ULG, USQ e UXG	
x_i^j	Nível do reservatório da usina i no período j	[m]
x_i^0	Nível do reservatório da usina i no último período do dia anterior	[m]
$y_{i,k}^j$	Variável binária - indica se a UG k da usina i período j é despachada	
ρ_i	Função de produtividade da usina i	
$\bar{\rho}_i$	Produtividade média da usina i	
η_i	Função de eficiência da usina i	

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Justificativa	1
1.2	Objetivo	4
1.3	Organização da Dissertação	4
2	PRÉ-DESPACHO DE UHES	6
2.1	Centrais Hidrelétricas	6
2.1.1	Descrição dos equipamentos	6
2.1.2	Despacho Ótimo de UG	8
2.1.3	Restrições operacionais	9
2.1.4	Partidas e Paradas das UGs	11
2.1.5	Curva de Carga diária	12
2.1.6	Curvas de eficiência	13
2.2	Planejamento da Operação no Brasil	14
2.3	Planejamento da Operação Energética	15
2.3.1	Programação da Operação de Curto Prazo ou Pré-Despacho	18
2.4	Modelos de despacho	18
2.4.1	Modelos de Otimização	19
2.4.2	Modelos de Computação Evolutiva	21
2.5	Problema de Pré-Despacho	23
2.5.1	O sistema energético do Médio São Francisco	23
2.5.2	Formulação do problema	25
3	COMPUTAÇÃO EVOLUTIVA	29
3.1	Algoritmos Genéticos	31
3.1.1	Introdução	31
3.1.2	Breve Histórico	32
3.1.3	O algoritmo	33
3.1.4	Terminologia dos AGs	34

3.1.5	Características dos AGs	35
3.1.6	Algoritmo Genético Básico	38
3.1.7	Elementos dos Algoritmos Genéticos	39
3.1.8	Parâmetros do AGs	43
3.1.9	População Inicial	44
3.1.10	Função de Adaptabilidade ou <i>Fitness</i>	44
3.1.11	Operadores Genéticos	45
3.1.12	Critério de Parada do AG	51
3.1.13	Diferenças e Vantagens dos AGs em relação a outros métodos de otimização	52
4	OTIMIZAÇÃO	55
4.1	Introdução	55
4.2	Otimização Mono-Objetivo	56
4.3	Otimização Multiobjetivo	56
4.4	Diferenças entre otimização Mono-Objetivo e Multiobjetivo	58
4.5	Pareto	59
4.6	Algoritmos Evolutivos (AE)	62
4.6.1	<i>Strength Pareto Evolutionary Algorithm</i>	63
5	IMPLEMENTAÇÃO COMPUTACIONAL	66
5.1	Condições de Contorno	68
5.2	Formulação Matemática	70
5.3	Técnica de resolução	72
5.3.1	Etapa 1: Cálculo da Geração das UHEs e Alocação da carga nas UHEs	73
5.3.2	Etapa 2: Despacho das UG	74
5.3.3	Fase 1: Maximizar Eficiência	74
5.3.4	Algoritmo Fase 1	75
5.3.5	Fase 2: Maximizar Eficiência e Minimizar Partidas/Paradas	78
5.3.6	Algoritmo Fase 2	79
6	CENÁRIOS DE ESTUDO	81
6.1	Ajustes das curvas de eficiência	81

6.1.1	Método dos Quadrados Mínimos	82
6.1.2	Método dos Quadrados Mínimos ponderados	83
6.2	Estudo de caso	85
6.2.1	Dados	85
6.3	Estrutura de dados	87
6.3.1	Planilha : Estudo de caso	88
6.4	Estudo de caso 1: Sobradinho	90
6.5	Estudo de caso 2: Paulo Afonso IV	97
7	RESULTADOS	106
8	CONCLUSÃO	118
8.1	Sugestão para trabalhos futuros	119
	REFERÊNCIAS	120

1 INTRODUÇÃO

1.1 Justificativa

A água é o recurso natural mais abundante no planeta e ela pode ser considerada um recurso renovável devido à capacidade de se recompor em quantidade, principalmente pelas chuvas, e de absorver poluentes. A sua classificação de recurso renovável, porém, é limitada pelo uso, que pressiona a sua disponibilidade pela quantidade existente e qualidade apresentada (ANEEL, 2010).

Segundo a Empresa de Pesquisa Energética - EPE (EPE, 2007), em 2030 a população brasileira será superior em 55 milhões de pessoas. Uma renda maior e melhor distribuída dessa população impulsionará o consumo de energia. A demanda per capita dessa energia evoluirá dos atuais 1,2 para 2,3 toneladas equivalentes de petróleo em 2030.

Segundo a Agência Nacional de Energia Elétrica (ANEEL, 2010), a principal fonte de geração de energia elétrica no Brasil origina-se de aproveitamentos hidrelétricos, representando, atualmente 66,2% da capacidade instalada total de geração no país, excluindo-se as importações e as outras fontes de energia (gás, petróleo, biomassa, nuclear, carvão mineral e eólica). A demanda de energia hidroelétrica aumentará de forma sustentada até 2030, devido ao aumento da geração, conforme é ilustrado na Figura 1.1.




Figura 1.1 - Evolução da demanda total de energia hidroelétrica no Brasil, 1970-2030.

Fonte: Plano Nacional de Energia (EPE, 2007)

Para acompanhar essa demanda, nesse cenário de referência, a EPE (2007) considerou a instalação de 88000 MW em usinas hidrelétricas (UHEs) entre 2005 e 2030, com aproveitamento de boa parte do potencial da Amazônia, além de pequenas centrais hidrelétricas (PCHs), centrais eólicas, centrais térmicas e centrais de outros tipos de fontes renováveis. A energia hidroelétrica irá acompanhar a sua posição de liderança na geração de energia elétrica, entretanto, sua participação na matriz elétrica deverá cair da elevada proporção de 90 % em 2005 para pouco mais de 75% em 2030. Apesar dessa diminuição, devido aos impactos ambientais e entre outros fatores, a oferta de energia hidroelétrica irá aumentar.

De acordo com Tolmasquim et al. (2007), as UHEs são a opção energética mais limpa e barata para o Brasil, apesar das críticas feitas por ambientalistas. É nesse contexto que a EPE (2009) desenvolve novos estudos de inventário para melhor avaliar o potencial hidrelétrico brasileiro e, também, estudos de viabilidade técnica, econômica e sócio-ambiental. COLOCAR CUSTO DA UHE

Para UHEs existentes, repotenciação e otimização de sua operação são opções para a expansão da oferta de energia hidroelétrica no Brasil. A operação de sistemas de geração de energia elétrica visa o atendimento de carga com confiabilidade e segurança. O planejamento da operação para a geração dessa energia engloba planejamentos a longo e a médios prazos, bem como a programação de Curto Prazo e a operação em tempo real. No planejamento de longo prazo é de-

terminado as gerações de energia hidroelétrica e termelétrica de forma que encontre uma estratégia que minimize o custo esperado da operação.

O planejamento de médio prazo procura determinar a programação de operação de cada UHE considerando as características dos sistemas de transmissão, os níveis dos reservatórios, os limites de geração de cada UHE e as metas determinadas pelo planejamento de longo prazo. Tal planejamento minimiza os custos operacionais do sistema interligado ao longo de todo período considerado e também, aloca a geração entre as usinas em período anual, com discretização mensal.

Nesta dissertação, o alvo principal de atenção é a programação de Curto Prazo ou Pré-Despacho. Essa programação possui um horizonte de operação semanal com discretização diária e requer uma representação matemática mais detalhada das restrições operativas. Nela é determinada a curva de geração de uma UHE e, a partir desta, são escolhidas as unidades geradoras (UGs) a serem despachadas em um determinado período de tempo. O despacho ótimo de carga (DOC) busca otimizar o processo de geração da UHE, utilizando os modelos detalhados de seu parque gerador, a previsão de carga e as restrições e características operativas das UGs, como por exemplo, suas eficiências.

Salmazo (1997) aponta que na operação de uma UHE, a eficiência das UGs é o principal fator de desempenho na geração de eletricidade. Assim, o conhecimento de seu comportamento possibilita um melhor despacho de geração e, conseqüentemente, ganhos energéticos. Portanto, é importante escolher adequadamente o número de máquinas em operação a cada intervalo de tempo. A determinação deste DOC pode não ser trivial, mesmo para um pequeno número de UGs. Esta dificuldade pode aumentar consideravelmente quando estas possuírem características distintas. Cabe observar que as UGs de uma mesma UHE podem possuir tais características atuais de operação distintas devido à consequência de diferentes históricos de operação e manutenção, mesmo que as características originais das UGs sejam idênticas.

Essa dissertação é resultado de um projeto de Pesquisa e Desenvolvimento (P&D), estabelecido entre a UNICAMP e a CHESF por meio da ANEEL durante dois anos. O objetivo do estudo foi fazer uma prospecção da vantagem do pré-despacho se fossem conhecidas as curvas de eficiência individualizadas das unidades geradoras, já que o custo para fazer tais medições é caro. Com isso, através do estudo o contratante irá avaliar se este investimento será benéfico para a empresa, obtendo ganhos de eficiência e posse de um modelo que já faz esse despacho.

1.2 Objetivo

O foco central deste trabalho é apresentar e implementar um modelo de otimização da operação diária das UHEs do Médio São Francisco, que maximize a eficiência de geração das UHEs e minimize o número de partidas e paradas de suas UGs, simultaneamente. Este modelo é resolvido em duas etapas, nas quais a Etapa 1 determina quanto cada UHE deve gerar a cada intervalo de tempo, e a Etapa 2 determina o número de UGs a serem despachadas e a carga de uma UHE específica. O estudo considerou oito UHE do sistema - Sobradinho (USB), Luiz Gonzaga (ULG), Apolônio Sales (UAS), Paulo Afonso I, II, III, (UPA), Paulo Afonso IV (USQ) e Xingó (UXG) - pertencentes à Companhia Hidro Elétrica do São Francisco (CHESF).

O modelo matemático abordado é de natureza não linear inteira mista e, para a sua solução, foram utilizadas técnicas de Computação Evolutiva (CE), em específico os Algoritmos Genéticos (AG), e de Programação Linear (PL). Essa metodologia foi desenvolvida em dois programas computacionais comerciais: *Microsoft Excel* (EXCEL, 2000) e *MATLAB* (MATLAB, 2010) que possui uma linguagem de programação de quarta geração (4GLS).

1.3 Organização da Dissertação

Neste capítulo (Capítulo 1) foi apresentado uma breve descrição sobre a programação de Curto Prazo ou Pré-Despacho. A ferramenta utilizada para solucionar o modelo proposto e os objetivos a serem alcançados com a realização deste estudo também foram apresentados.

O Capítulo 2 apresenta uma revisão bibliográfica sobre centrais hidrelétricas, tais como a descrição de seus equipamentos e as restrições e características operativas das UGs. Planejamento da operação energética e trabalhos relacionados com DOC e AG também são mostrados nesse capítulo.

No Capítulo 3 é apresentado uma descrição sobre CE, principalmente os AG. Codificação, função de avaliação, métodos de seleção, operadores, entre outros, são descritos detalhadamente .

O Capítulo 4 faz uma discussão teórica sobre Otimização Mono-Objetivo e Multiobjetivo,

Algoritmos Evolutivos (AEs) e *Strength Pareto Evolutionary Algorithm* (SPEA).

No Capítulo 5 é apresentada a formulação matemática do problema e a sua técnica de resolução.

O Capítulo 6 apresenta os cenários de estudos e as metodologias utilizadas.

E, finalmente, no Capítulo 7 é apresentado os resultados e no Capítulo 8 as conclusões dessa dissertação, bem como sugestões para trabalhos a serem realizados, posteriormente.

2 PRÉ-DESPACHO DE UHES

2.1 Centrais Hidrelétricas

Segundo a ANEEL (ANEEL, 2008), a participação de hidroeletricidade na produção total de energia elétrica em 2006 no Brasil foi de 83,2%. Um sistema de energia elétrica pode ser dividido em meios de produção e de transporte, também centros de consumo. Uma UHE possui equipamentos de produção responsáveis pela transformação da energia potencial dos cursos d'água em energia elétrica.

Neste capítulo serão descritos as características básicas de uma UHE, levando em consideração a sua devida importância para o presente estudo.

2.1.1 Descrição dos equipamentos

Os principais elementos da estrutura física e operativa de uma usina são: barragem, canal de fuga, condutos forçados e casa de máquina. A energia potencial hidroelétrica é obtida através do armazenamento de água no reservatório e a barragem possui o objetivo de reter água permitindo a captação dela em um nível adequado. Os condutos forçados levam a água até a casa de força que abriga as turbinas, geradores e outros tipos de equipamentos.

Na casa de máquina, a água é utilizada para girar as turbinas que são formadas por pás conectadas ao gerador, convertendo a energia cinética em mecânica, e os geradores, que convertem a energia mecânica em energia elétrica. Após a água passar pelas turbinas, esta retorna ao rio através de um canal, denominado canal de fuga. O vertedouro é responsável por permitir o controle de nível da água do reservatório, principalmente nos períodos de cheia. A Figura 2.1 apresenta um esquema de uma UHE com seus principais componentes.




Figura 2.1 - Corte longitudinal de uma UHE com os seus principais elementos físicos.

Fonte: Adaptado de Souza et al. (1999)

O reservatório de uma UHE pode ser classificado em dois tipos: acumulação e fio d'água. Segundo ANEEL (2008), os reservatórios de acumulação são utilizados quando as vazões de estiagem do rio são inferiores à necessária para fornecer a potência para suprir a demanda máxima do mercado consumidor.

As usinas a fio d'água são empregadas quando as vazões de estiagem do rio são iguais ou maiores que a descarga necessária à potência a ser instalada para atender à demanda máxima prevista. A Figura 2.2 mostra uma cascata formada por algumas UHEs do sistema brasileiro.




Figura 2.2 - Cascata de UHEs do Rio São Francisco.

Segundo Soares e Salmazo (1997), a eficiência das UGs é o principal fator que influencia no desempenho da geração de eletricidade em uma UHE. Assim, o conhecimento do seu comportamento possibilita um melhor despacho de geração e consequentes ganhos energéticos.

A altura de queda bruta da usina é outro aspecto importante para a geração de energia elétrica. Essa altura é a diferença entre o nível do reservatório e o nível do canal de fuga.

2.1.2 Despacho Ótimo de UG

O DOC resolve o problema de otimização para alocar a geração das UGs num determinado intervalo de tempo otimizando a geração da UHE, podendo ser implementado, computacionalmente, através de técnicas da Computação Evolutiva. Nas usinas termelétricas (UTES), esta alocação de geração tem como objetivo otimizar os custos do combustível, e no caso das UHEs, a relação entre

o despacho e o custo de geração não é tão imediata quanto nas UTEs. De acordo com Santos et al. (2002), no caso das UHEs, um critério viável seria a otimização de sua produtibilidade, ou seja, a maximização da conversão da energia potencial da água acumulada no reservatórios em energia elétrica.

A produção de energia elétrica de uma UHE está diretamente relacionada com a altura de queda líquida e a vazão turbinada, principalmente com o rendimento das UGs, também denominado conjunto turbina-gerador. É importante que um modelo de despacho obedeça as restrições operativas e leve em consideração, também, características operativas das UGs como, por exemplo, suas eficiências.

2.1.3 Restrições operacionais

Zonas proibidas de operação

As zonas proibidas de operação podem causar desde o desgaste excessivo até o desligamento forçado de uma UG para a sua manutenção e recuperação. Estes problemas são causados por um fenômeno chamado Cavitação (CALAINHO et al., 1999).

A Cavitação consiste na vaporização de um líquido pela redução da sua pressão durante o movimento de um equipamento hidrodinâmico, como em hélices de navios, bombas centrífugas, turbinas hidráulicas e válvulas. No caso das UHEs, o fluxo de água, ao ser acelerado, tem uma redução de pressão para que sua energia mecânica mantenha-se constante. Devido a esta aceleração, a pressão diminuiu até atingir a pressão de vapor do mesmo formando-se pequenas bolsas, bolhas ou cavidades. As mencionadas bolhas são submetidas a um aumento inesperado de pressão mais adiante no escoamento, ocorrendo a implosão destas que liberam poderosas forças nas turbinas.

Se as ondas de choque geradas por essas implosões sucessivas forem próximas a uma superfície sólida, trincas microscópicas irão aparecer e com o tempo irão crescer e deslocar o material da superfície, originando uma cavidade de erosão. A erosão por Cavitação causa enormes prejuízos para o setor elétrico quando se trata de uma usina, pois compromete o funcionamento de suas

turbinas hidráulicas. As principais consequências desta erosão são constantes paradas para recuperação de regiões cavitadas, ruídos excessivos, vibrações e redução da eficiência e da potência. A eficiência global de geração da UHE no despacho pode ser comprometida diretamente por essa diminuição da eficiência (SOUZA et al., 1999).

Por isso, as zonas proibidas de operação devem ser evitadas onde ocorrem a Cavitação, limitando a faixa de operação das UGs. De acordo com Calainho et al. (1999), o fenômeno de Cavitação também pode ocorrer em outras estruturas hidráulicas das UHEs, como o vertedouro, válvulas, canais, túneis, comportas e, como mencionado, nas turbinas. As turbinas Francis e Kaplan possuem uma maior incidência desse fenômeno devido a uma maior frequência de depressão ocorridas nas regiões convexas próximas à saída das pás rotoras.

Uma melhor maneira de prevenir a cavitação nas turbinas hidráulicas é efetuada no ensaios em laboratórios especializados em escala reduzida. Porém esse método acompanha algumas imprecisões devido ao fato de efeitos de escala existente entre as condições de ensaio e as de operação real da unidades geradoras.

Reserva girante

Durante a operação das usinas de geração (térmica, hidráulica ou eólica), a potência gerada deve corresponder à potência demandada a cada instante. De acordo com Nilsson et al. (1998), a reserva girante é uma reserva de geração que deve garantir a confiabilidade do sistema no caso da ocorrência de falhas ou erros na previsão de demanda.

Segundo o Operador Nacional do Sistema Elétrico - ONS (ONS, 2009), essa reserva é extremamente fundamental para a manutenção da segurança operacional elétrica, pois suaviza os riscos de não atendimento as cargas e as estratégias adotadas para o controle automático de geração.

2.1.4 Partidas e Paradas das UGs

Nesta dissertação, um dos objetivos do modelo proposto está relacionado com a minimização do número de partidas e paradas das UGs. São poucos trabalhos, na literatura, que retratam esta questão, pois a grande maioria são sobre partidas e paradas de unidades termelétricas. Esta preferência deve-se ao fato de a maior parte dos sistemas de energia elétrica ser de predominância termelétrica e também porque os custos de partidas e paradas de suas unidades são mais nítidos do que das unidades hidráulicas.

Entretanto, em alguns estudos os custos de partidas e paradas das UGs possuem uma grande importância, uma vez que diminui a vida útil das UGs e aumenta o serviço de manutenção nas mesmas. No trabalho apresentado por Nilsson e Sjelvgrén (1997) buscou-se quantificar o custo associado às partidas e paradas das UGs através de entrevistas aos maiores produtores de energia elétrica da Suécia. Foram apontados vários aspectos causadores de custo nas partidas e paradas nas entrevistas, sendo algumas de maior relevância como degradação do isolamento dos enrolamentos do gerador devido às mudanças de temperatura, desgastes dos equipamentos mecânicos e falha nos equipamentos de controle durante as partidas e paradas. De modo geral as entrevistas apontaram para um valor aproximado de 3US\$/MW vezes a potência nominal da unidade.

Este mesmo custo foi adotado na dissertação de mestrado de Encina (1999), na qual ele implementou um modelo de Pré-Despacho considerando as partidas e paradas para a UHE de Itaipu. Levando em conta os custos de partidas e paradas sobre a solução do problema, o autor conclui que os custos são menos relevantes que otimizar a produtividade e que é possível diminuir significativamente os custos das partidas sem alterar na produtividade da UHE. Este modelo foi resolvido via Programação Dinâmica.

A alteração da Curva de Carga, ao longo de um dia, promove a ação de ligar e desligar as UGs para conservar um equilíbrio entre a carga e a geração, de modo que seja inevitável as partidas e paradas durante do dia.

2.1.5 Curva de Carga diária

As UHEs devem operar com uma certa quantidade de UGs para atender a demanda da carga requerida pelo sistema num determinado período de tempo. Normalmente, o consumo de energia apresenta uma Curva de Carga que pode ser segmentada em três faixas distintas. A primeira faixa representaria o consumo no início do dia, ou seja, um consumo baixo. A segunda faixa seria um consumo médio e a terceira compreenderia o período no qual exista um grande consumo de energia, classificado como horário de pico ou ponta. Este tipo de caracterização da curva pode ser observada na Figura 2.3.




Figura 2.3 - Exemplo de uma Curva de Carga diária de Sobradinho.
Fonte: Baseado em dados fornecidos pela CHESF no dia 10 de setembro de 2007.

Pode-se notar que a Curva de Carga diária apresenta um comportamento bastante variável ao longo do dia, indicando que em alguns intervalos a usina deve aumentar ou diminuir o número de máquinas despachadas, de forma a deixá-las operando em pontos próximos do ótimo. Este número de UGs deve ser determinado para cada intervalo de tempo.

2.1.6 Curvas de eficiência

Alguns dispositivos mecânicos ou elétricos durante os seus funcionamentos sujeita-se a sofrer imperfeições, como atritos entre os elementos físicos, aquecimento, condições não ideais de temperatura e pressão, entre outros. A UG, por consequência, também está sujeita a esses tipos de fatores e, em virtude disso, o aproveitamento da energia potencial da água nos reservatórios é alterado na transformação em energia elétrica.

A variação da eficiência de cada UG depende da altura de queda da usina, da vazão turbinada e da potência gerada pela unidade. Uma curva de eficiência, em função da altura de queda e da potência gerada ou da vazão turbinada, é chamada de Curva Colina. Nas Figuras 2.4 e 2.5 tem-se, para efeito de exemplo, duas curvas colinas.




Figura 2.4 - Curva Colina de uma UG em função da altura de queda da potência.

Fonte: *Software* HYDROLAB (ELETROENERGÉTICOS, 2006).




Figura 2.5 - Curva Colina de uma UG em função da altura de queda e da vazão turbinada.

Fonte: Baseado em Souza et al. (1999)

A Curva Colina, frequentemente, informa as zonas proibidas de geração explicadas, detalhadamente, na Subseção 2.1.3. A maioria dos estudos apresentados sobre despacho, considera os dados de eficiência das UGs como sendo iguais, tendo a carga da UHE repartida, igualmente, entre as máquinas. O presente trabalho desenvolvido considera os dados individuais atualizados das UGs.

2.2 Planejamento da Operação no Brasil

A discussão do planejamento da operação dos sistemas hidrotérmicos no Brasil vem motivando pesquisas teóricas, tanto nos centros de pesquisa das universidades quanto nas empresas

geradoras de energia elétrica.

O Brasil é um país que possui grandes dimensões territoriais e, por isso a sua estrutura de produção e transmissão de energia elétrica é bastante particular, com restrições em suas transmissões. Atualmente, as atividades do planejamento da operação desta geração e transmissão do sistema elétrico brasileiro está sob a responsabilidade do Operador Nacional do Sistema (ONS).

O ONS é uma entidade de direito privado, sem fins lucrativos, responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), sob a fiscalização e regulação da ANEEL.

2.3 Planejamento da Operação Energética

O planejamento de um sistema elétrico é estruturado em duas partes:

1. Planejamento de Expansão

Etapa na qual tem-se por objetivo analisar diferentes estratégias da expansão do sistema elétrico em relação à geração e transmissão, estabelecendo-se um cronograma de trabalho de novos projetos que visam atender o crescimento da demanda do sistema, cumprindo determinados critérios de confiabilidade e minimizando os custos de operação e investimento ao longo do horizonte de planejamento.

2. Planejamento de Operação

Para UHEs existentes ou para aquelas que ficarão prontas durante o horizonte de estudo, o objetivo do planejamento de operação é determinar uma estratégia de geração para cada uma destas, minimizando os custos operativos esperados na complementação do mercado através de geração termelétrica, importação e racionamento. Quando o sistema é puramente hidráulico, o objetivo é maximizar as reservas de energia (FORTUNATO et al., 1990).

De acordo com a natureza das UGs, estas podem ser classificadas em três tipos: hidrelétricos, hidrotérmicos e termelétricos. Num sistema termelétrico existe regiões onde as condições físicas dificultam a geração hidroelétrica. Esses são compostos por unidades termelétricas que transformam a energia térmica em energia elétrica proveniente da queima de combustíveis fósseis ou da

biomassa.

As UHEs são as unidades geradoras do sistema hidrelétrico que se aproveitam das quedas d'água para gerarem energia elétrica. Já o sistema hidrotérmico é composto por UHEs e por UTEs ligadas aos centro de carga através de um sistema de transmissão, conforme a Figura 2.6.

A natureza do sistema brasileiro é hidrotérmica e possui uma participação de 83% de toda energia elétrica gerada no país (ANEEL, 2008). De acordo com a *International Energy Agency* (IEA, 2010), o Brasil é um dos países responsáveis por quase 50% de toda produção mundial de energia hidroelétrica, entre Canadá, Estados Unidos, Rússia e China .




Figura 2.6 - Estrutura básica de um sistema hidrotérmico.

O planejamento da operação de um sistema hidrotérmico tem como alvo principal definir estratégias de operação para cada UHE do sistema, minimizando o custo operativo esperado ao longo de um período. Ele também propõe definir como os recursos disponíveis devem ser empregados para a geração de energia elétrica. A natureza de sistemas energéticos que possui uma forte predominância hidráulica, necessita de um planejamento de operação sobre um horizonte de longo prazo, devido às variações anuais dos recursos hídricos e das demandas de carga.

De acordo com Santos (2001), esta cadeia de planejamento depende, fundamentalmente, das características hidrológicas do sistema, da capacidade de regulação dos reservatórios e do acoplamento hidráulico entre as UHEs situadas no mesmo rio. Este planejamento possui quatro etapas,

conforme na Figura 2.7.




Figura 2.7 - Etapas do Planejamento de Operação.

No planejamento de longo prazo é determinada as gerações das UHEs e UTEs que minimize o valor de custo esperado da operação, para discretizações mensais, levando em conta as incertezas das afluências futuras. No planejamento da operação de médio prazo determinam-se as políticas de operação de cada usina, individualmente, atendendo às restrições operativas e a demanda global de cada intervalo. Ao mesmo tempo, é também determinada a minimização do custo operacional do sistema. Nesta etapa são definidas as metas energéticas para a programação de curto prazo e são alocados a geração entre as UHEs em um período anual, com uma discretização semanal.

Nessa dissertação, o alvo principal de planejamento de operação é o de Curto Prazo ou Pré-Despacho, que será explicado a seguir.

2.3.1 Programação da Operação de Curto Prazo ou Pré-Despacho

A programação de Curto Prazo demanda, devido à sua proximidade da operação em tempo real, uma representação matemática mais detalhada do sistema. A representação da rede elétrica, suas limitações operativas, bem como uma representação do sistema hidráulico são alguns exemplos deste detalhamento. A formulação matemática deste problema deve considerar uma modelagem realista das UGs. Para o caso particular de sistemas hidrotérmicos, com predominância hidrelétrica, requer-se um elevado grau de detalhamento na representação das UGs hidrelétricas.

Nessa programação pode-se determinar a curva de geração de uma UHE e, a partir desta, existe a possibilidade de escolher as UGs a serem despachadas. O despacho aloca a geração de cada UG a cada intervalo de tempo de forma a otimizar a geração. O despacho de máquinas é de extrema importância no planejamento da operação, pois é através dele que defini-se uma melhor maneira de atender o comprometimento assumido na programação diária e a efetuação dos ajustes com o auxílio da supervisão. Esta supervisão acompanha o atendimento de carga, a capacidade de produção das UGs, capacidade do sistema de transformação, transmissão e etc, que variam a cada instante.

A programação diária possui como objetivo calcular os despachos ótimo horário de geração das UHEs, determinando uma configuração de UGs para serem alocadas em um determinado período de tempo. Esta alocação é obtida através de técnicas de otimização. Nesta fase também são dados os valores de energias que cada usina, termelétrica ou hidrelétrica, deverá produzir e a reserva de potência operativa que deverá sustentar nas próximas 24 horas.

2.4 Modelos de despacho

A literatura apresenta uma parcela significativa de trabalhos que relacionam o problema da programação da operação com distintas abordagens, que variam conforme a aplicabilidade do mesmo. O objetivo desta dissertação é apresentar e implementar uma metodologia de otimização para o problema da operação diária das UHEs em cascata do Médio São Francisco e de uma UHE

em específico. Sucintamente, são descritos alguns trabalhos sobre a operação diária ou despacho de UHE.

Programação Linear e Não Linear, Inteiro Misto, AG, Busca Heurísticas e entre outros são alguns dos diversos métodos utilizados por autores na resolução de problemas de despacho de UGs em UHEs. Na sequência, segue uma descrição dos trabalhos sobre o tema, dividido em duas partes. Na subseção Modelos de Otimização são expostos os que utilizam modelos de Otimização Linear, Não Linear e Inteira e também Buscas Heurísticas. Já na Subseção Modelos de Computação Evolutiva são apresentados àqueles que utilizam técnicas da CE.

2.4.1 Modelos de Otimização

Ohishi et al. (2001) apresentaram um modelo de Pré-Despacho para as UHEs do Rio Parapanema, determinando o número de máquinas em operação em cada UHE e o seu despacho de geração, considerando os limites de geração, o mercado a ser atendido e outras restrições operacionais. O modelo proposto é de natureza mista e foi resolvido através de uma metodologia híbrida em dois passos, sendo o primeiro denominado Escolha da Configuração (EC) e o outro como Despacho de Geração (DG). Na EC trata-se de um problema de Programação Inteira resolvido através de uma Busca Heurística determinando a quantidade de UGs a serem despachadas; já no DG foi utilizada a Relaxação Lagrangeana para a determinação da geração das UGs ativas.

Salmazo (1997) também buscou definir a geração a nível das UGs em base horária através da minimização das perdas no sistema de produção e transmissão, atendimento dos requisitos de carga, metas de geração e intercâmbios. A técnica de solução utilizada também foi a Relaxação Lagrangeana associada a uma busca heurística para selecionar as UGs em operação.

Em sua dissertação de mestrado, Ferreira (1991) utilizou a Programação Dinâmica na otimização da operação da cascata do Rio Iguaçu, que é formado por quatro UHEs pertencentes a duas empresas distintas. Os resultados computacionais obtidos mostraram que existem ganhos energéticos adotado de regras operativas não convencionais, específicas para a cascata em estudo.

Encina (2006) em sua tese de doutorado ou Encina et al. (2008), apresentou um modelo de Despacho Ótimo de UGs adotando como critério de desempenho a avaliação das perdas no sistema

de geração e o custo associado ao número de partidas e paradas. Nesse estudo foram utilizadas 16 UHEs do Sistema Elétrico Brasileiro, totalizando 100 UGs. O modelo foi dividido em dois subproblemas denominados Despacho das Unidades e Despacho de Geração. O primeiro escolhe as UGs que estarão gerando em cada UHE, considerando-se que são idênticas dentro de uma mesma UHE. Nele foi utilizado Programação Dinâmica que visava a minimização dos custos referentes ao número de partidas e paradas das UGs e as perdas hidráulicas. No segundo, o número de UGs ativas em cada UHE já está pré-estabelecido e a Relaxação Lagrangeana foi utilizado para otimizar a geração entre as UGs definidas. Nele foi tomado como referência os dados de programação de um dia típico de operação. A aplicação desses dois subproblemas se dá, iterativamente, até que se obtenha a solução ótima do problema.

Encina et al. (2004) abordou uma metodologia para a otimização do despacho de unidades geradores hidráulicas adotando como critério as perdas hidráulicas no sistema de adução, a elevação do canal de fuga e as variações de rendimento das UGs. A Programação Dinâmica foi utilizada para resolver este despacho numa base horária levando em conta os custos de partidas e paradas das unidades. Isto foi aplicado num sistema com 16 UHEs do Sistema Elétrico Brasileiro. Busca Heurística e Relaxação Lagrangeana também foram empregados na otimização.

Kadowaki et al. (2007) apresentaram uma modelagem para a programação diária da operação para o Sistema Interligado Nacional (SIN), com 95 UHEs e 23 UTEs. O problema formulado é Misto e Não Linear e foi dividido em três modelos distintos: modelo de despacho de máquinas e de geração (HydroDesp), de simulação hidráulica a usinas individualizadas em base horária (Hydro-SimCP) e um de fluxo de potência ótimo em corrente contínua (FPOCC). O problema é resolvido através da resolução interativa desses três modelos e a resolução foi baseada numa metodologia híbrida, incluindo aspectos heurísticos, juntamente, com modelos de otimização e Relaxação Lagrangeana.

Encina et al. (2002) mostraram um modelo de Programação Dinâmica para otimizar o número de UGs em operação num horizonte de base horária na UHE de Itaipú. Ele também visava minimizar custo de partidas e paradas das unidades e o custo associado às perdas no sistema. O problema demonstrou que é importante levar em conta a representação da cada UG, individualmente, a fim de modelar com precisão a sua eficiência.

Um problema de despacho de natureza inteira e não linear foi desenvolvido por Finardi e Silva (2005). As unidades geradoras foram alocadas à diversas faixas de operação e variáveis inteiras

binárias indicavam em qual dessas faixas cada unidade iria trabalhar. As combinações das variáveis que garantiriam soluções factíveis foram encontradas através de uma técnica baseada no método de *Branch and Bound*. Foi através do método do gradiente projetado que a melhor combinação foi escolhida. Este modelo de despacho proposto possui uma certa parecença com esta dissertação, pois as UGs também são tratadas individualmente, considerando que estas sendo não idênticas dentro de uma mesma UHE.

Rodrigues et al. (2006) abordaram o problema de programação da operação energética de sistemas hidrotérmicos através do uso da relaxação lagrangeana. Ele foi decomposto em subproblemas menores e mais fáceis de serem resolvidos, entre eles o subproblema de despacho das unidades hidrelétricas de natureza não linear, mas contínuo. Para a resolução do referido foi proposto um algoritmo de enumeração exaustiva de estados do problema resolvidos pelo método de Lagrangeano Aumentado.

Colnago (2007), em sua dissertação de mestrado apresentou um modelo de despacho ótimo em uma UHE com seis unidades tratadas, individualmente. A formulação do problema proposto é não linear inteiro misto e não convexo. Para a sua resolução foram utilizadas os métodos de busca global e local através de um *software*, resultando ganhos de eficiência no despacho.

2.4.2 Modelos de Computação Evolutiva

Conalgo e Barros (2009) propuseram um modelo de despacho ótimo multiobjetivo para a operação de uma UHE. O modelo é composto de dois algoritmos baseados nos AG. O primeiro algoritmo é utilizado para alocar as UGs e visa maximizar a eficiência da UHE em uma hora base. A segunda etapa tem por objetivo maximizar a eficiência e minimizar o número de partidas e paradas das UGs. Os dados utilizados na simulação foram obtidos em um dia de operação de uma UHE real.

O modelo de despacho proposto por Santos (2001), assim como Encina (2006), foi dividido em dois subproblemas denominados Despacho de Unidades (DU) e Despacho de Geração (DG). O DG foi resolvido via relaxação lagrangeana e no DU utilizou-se os algoritmos genéticos. A importância do AG na aplicação deste subproblema foi para fixação das variáveis inteiras. A sua

função objetivo levou em conta a minimização das perdas por partidas e paradas e por perdas hidráulicas das UHEs. Esta metodologia foi aplicada ao estudo de caso real do sistema de usinas do rio Paranapanema. Santos (2001) conclui que, a minimização das perdas hidráulicas é mais importante que a outra perda.

A mesma abordagem utilizada por Santos (2001) foi usada por Santos e Ohishi (2004). A diferença entre estes foi a inclusão de um terceiro estudo de caso em um sistema hidrelétrico com 47 unidades geradoras. Neste problema, os autores concluíram que, quanto maior o número de unidades empregadas, maior é o tempo computacional, mas não exponencialmente.

Em um outro modelo de despacho proposto por Abido (2006), também utilizou-se da representação real das variáveis nos AG. Em tal problema foi usado um operador de cruzamento denominado *blend crossover* e o de mutação denominado mutação não uniforme. Os algoritmos multiobjetivos também foram utilizados para a resolução do problema de despacho, tais como *Strength Pareto Algorithm* (SPEA)¹, *Niched Pareto genetic algorithm* (NPGA) e *Nondominated Sorting Genetic Algorithm* (NSGA).

Villasanti et al. (2004) usaram dois algoritmos evolutivos multiobjetivos combinados com um método heurístico para a resolução de um problema de despacho que visava maximizar a eficiência de geração e minimizar o número de partidas e paradas das UGs. Empregou-se o método heurístico para adquirir soluções factíveis para o problema.

Os AG foram empregados no modelo de despacho sugerido por Yalcinoz e Altun (2001). As soluções iniciais foram geradas através de uma Rede Neural *Hopfield* e os operadores genéticos utilizados foram o *crossover* aritmético, mutação e para a seleção de ascendentes, o elitismo. Para a obtenção de uma melhor resolução, eles realizaram uma comparação entre o método proposto com outros quatro métodos, sendo estas técnicas de algoritmos genéticos e Redes Neurais *Hopfield* melhoradas, AG controlados pela lógica *fuzzy* e uma técnica baseada no método sequencial quadrático. Dentre estas técnicas, os resultados mostraram que o modelo proposto foi competitivo com as Redes Neurais melhorada e com o método sequencial quadrático.

Os AG também foram utilizados em uma metodologia proposta por Khatami et al. (2001) para o despacho de UGs da UHE MICAS pertencente a empresa *BC-Hydro* no Canadá. Esta empresa possui uma base de dados com mais de 25 mil combinações de unidades geradoras, com diferentes alturas de queda e diferentes cargas da usina, com a alocação ótima entre as UGs para

¹Este algoritmo será explicado detalhadamente na Subseção 4.6.1

cada combinação possível. Esta base foi empregada para fazer o despacho dinâmico. A otimização diária do problema é desenvolvida em seis etapas, havendo uma conexão do *status* da UG do último período com o primeiro da seguinte. O objetivo do modelo é maximizar a eficiência na geração e minimizar o número de partidas e paradas e cada solução do problema é um vetor binário de 16 posições que indicam, em cada período, se a UG foi despachada ou não. O método dos pesos foram empregados para a otimização multiobjetivo.

2.5 Problema de Pré-Despacho

2.5.1 O sistema energético do Médio São Francisco

O rio São Francisco nasce na Serra da Canastra em Minas Gerais e atravessa os estados de Minas Gerais (MG), Bahia (BA), Pernambuco (PE), Sergipe (SE) e Alagoas (AL). Ele possui uma extensão de 3200 km, tendo uma bacia hidrográfica da ordem de 630000 km^2 . A cascata do Médio São Francisco é formada pelos aproveitamentos das UHEs Sobradinho, Luiz Gonzaga, Apolônio Sales (Moxotó), Paulo Afonso I, II, III, IV e Xingó. Essas UHEs constituem o núcleo central do sistema produtor de energia elétrica da região Nordeste (CHESF).

A Figura 2.8 apresenta a localização do Médio São Francisco, juntamente com as UHEs.



Figura 2.8 - Sistema do Médio São Francisco com as UHEs nele localizadas.

Fonte: Adaptado do site *Peixes e Pesca no Rio São Francisco*.

O aproveitamento hidrelétrico de Sobradinho está localizado no estado da Bahia, distando cerca de 40 km à montante das cidades de Juazeiro (BA) e Petrolina (PE). O reservatório dessa UHE tem cerca de 320 km de extensão e possui uma casa de força com seis UGs acionadas por turbinas Kaplan com potência unitária de 175.050 kW, totalizando 1,050.300 kW.

A UHE Luiz Gonzaga localiza-se no estado de Pernambuco, 25 km à jusante da cidade de Petrolândia. Ela está situada a 50 km à montante do Complexo Hidrelétrico de Paulo Afonso, possuindo, além da função de geração de energia elétrica, a de regularização das vazões afluentes diárias e semanais daquelas usinas. Nela estão instaladas seis UGs acionadas por turbinas Francis com potência unitária de 246.600 kW, totalizando 1479600 kW.

O COMPLEXO de Paulo Afonso é formado pelas UHEs Apolônio Sales e Paulo Afonso I, II, III e IV. Este COMPLEXO produz 4.279.600 kW, energia gerada a partir da força das águas da cachoeira de Paulo Afonso, um desnível natural de 80 metros do rio São Francisco.

O aproveitamento hidrelétrico de Apolônio Sales, encontra-se localizado no município de Delmiro Gouveia, em Alagoas. Integrante do COMPLEXO, ela situa-se a cerca de três km à montante da barragem Delmiro Gouveia, de modo que a água turbinada em suas UGs aciona também as UHEs de Paulo Afonso I, II e III. O seu reservatório fornece a água necessária para o acionamento da UHE de Paulo Afonso IV, situado paralelamente ao mesmo. Ela possui quatro UGs acionadas por turbinas Kaplan, cada uma com 100.000 kW, totalizando uma potência instalada de 400.000 kW.

A UHE Paulo Afonso I localiza-se na cidade de Paulo Afonso, estado da Bahia e possui três UGs acionadas por turbinas Francis com potência unitária de 60.000 kW, totalizando 180.000 kW. O aproveitamento hidrelétrico de Paulo Afonso II é constituído por seis UGs acionadas por turbinas Francis, sendo duas com potência unitária de 70000 kW, uma com 75.000 kW e três com 76000 kW, totalizando 443.000 kW. A UHE Paulo Afonso III possui quatro UGs acionadas por turbinas Francis, com potência unitária de 198.550 kW, totalizando 794.200 kW.

O aproveitamento hidrelétrico Paulo Afonso IV possui seis UGs acionadas por turbinas Francis de eixo vertical, cada uma com capacidade nominal de 410.400 kW, totalizando 2.462.400 kW.

A UHE Xingó está localizada entre os estados de Alagoas e Sergipe e com relação ao rio São Francisco está localizada a cerca de 65 km à jusante do COMPLEXO de Paulo Afonso. Ela é composta por seis UGs com 527.000 kW de potência nominal unitária, totalizando 3.162.000 kW de potência instalada.

A seguir, será apresentado o problema de programação da operação diária dessas UHEs.

2.5.2 Formulação do problema

O problema de programação da operação das UHEs do sistema do Médio São Francisco é tratado através de uma formulação matemática de natureza Não Linear Inteira Mista e com não linearidades, tanto na função objetivo como também nas restrições. Pode, portanto ser colocada da

seguinte forma:

$$\text{Max } \frac{\sum_{j=1}^{24} d^j}{\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{y_{i,k}^j p_{i,k}^j}{\eta_i(p_{i,k}^j)}} \quad (2.1)$$

$$\text{Min } \sum_{j=2}^{24} \sum_{i \in UHE} \sum_{k=1}^{n_i} |y_{i,k}^j - y^j - 1_{i,k}| \quad (2.2)$$

$$\text{s.a. } \sum_{i \in UHE} \sum_{k=1}^{n_i} p_{i,k}^j = d^j - \bar{G} \quad (2.3)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{USB}^j}{\rho_{USB}(x_{USB}^0, p_{USB,k}^j)} = 24Q_{USB} \quad (2.4)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{ULG}^j}{\rho_{ULG}(x_{ULG}^0, p_{ULG,k}^j)} = 24Q_{ULG} \quad (2.5)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{USQ}^j}{\rho_{USQ}(x_{USQ}^0, p_{USQ,k}^j)} = 24Q_{USQ} \quad (2.6)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{UXG}^j}{\rho_{UXG}(x_{UXG}^0, p_{UXG,k}^j)} = 24Q_{UXG} \quad (2.7)$$

$$p_{i,k}^{j,min} y_{i,k}^j \leq p_{i,k}^j \leq p_{i,k}^{j,max} y_{i,k}^j \quad (2.8)$$

$$y_{i,k}^j \in \{0,1\} \quad (2.9)$$

para $i \in UHE = \{USB, ULG, USQ, UXG\}$, $k = \{1, \dots, n\}$ e $j = 1, \dots, 24$.

A resolução desse problema foi dividido em 2 etapas e tratado através de técnicas da Programação Linear e dos Algoritmos Genéticos que serão explicados, detalhadamente, no capítulo a seguir (Capítulo 3).

Esse problema possui caráter multiobjetivo, pois as funções objetivos 5.9 e 5.10 buscam maximizar a produtividade e minimizar o número de partidas e paradas das UGs, respectivamente. Para cada UG, a sua produtividade é representada individualmente e a cada uma delas está associada uma variável booleana que indica se ela está em operação em um determinado intervalo de tempo. A Equação 5.11 representa o atendimento do mercado, uma para cada intervalo de tempo e as Equações 5.12 à 5.15 representam as restrições de defluência diária média para cada UHE. E, finalmente, a Restrição 5.16 representa os limites de geração de cada UG e a Restrição 5.17 define as variáveis booleanas.

A Figura 2.9 ilustra a resolução do problema.




Figura 2.9 - Esquema do problema de otimização na Etapa 1.

O desafio de construir um modelo matemático é conciliar simplicidade com completude. Simplicidade no sentido de possuir a capacidade de excluir o que não é relevante para o problema e completude no sentido de conter tudo que é essencial para o problema. Dessa forma, as UHEs Apolônio Sales e Paulo Afonso I, II e III não aparecem na formulação matemática porque suas turbinagens foram fixadas por conveniência operacional, ou seja, foram consideradas constantes

deixando a formulação matemática simplificada.

3 COMPUTAÇÃO EVOLUTIVA

Segundo Back et al. (1997), o termo Computação Evolutiva surgiu em 1991, incorporando diversos métodos computacionais inspirados na genética e no princípio Darwiniano da evolução das espécies. Estes métodos baseiam-se na avaliação, nas modificações e na seleção que uma população está sujeita a sofrer.

As técnicas usadas na CE utilizam algoritmos de busca chamados Algoritmos Evolutivos (AEs). Os AEs tentam abstrair e imitar os mecanismos na resolução de problemas que requerem adaptação, busca e otimização objetivando encontrar uma solução ótima, um indivíduo ótimo de uma população geneticamente refinada (BELPIEDE, 2006).

Atmar (1994) cita que dentre os principais ramos da CE estão as técnicas de Algoritmos Genéticos, Programação Evolutiva (PE) e Estratégias Evolutivas (EEs). Cada uma destas técnicas possuem algo em comum: a abordagem dos conceitos de seleção, reprodução, competição e busca aleatória de indivíduos em uma população.

As estratégias evolutivas foram introduzidas na Alemanha, na Universidade Técnica de Berlim, inicialmente por Rechenberg e depois desenvolvidas por Schwefel. Trata-se de um algoritmo empregado na resolução de problemas de otimização com parâmetros reais (Rechenberg (1965), Lopes et al. (2006)).

Na Universidade da Califórnia, em *Los Angeles*, Fogel desenvolveu a PE, que consistia na evolução de populações com máquinas de estados finitos, submetendo-as a transformações unitárias. Ela é aplicada em problemas de otimização de forma análoga às EEs (Fogel et al. (1966), Back (1996), Lopes et al. (2006)).

Segundo Goldberg (1989), os AGs são métodos computacionais de busca, baseados no mecanismo de seleção natural e da genética. Os mesmos foram introduzidos por Holland (1962) com a finalidade de solucionar problemas de otimização. Eles compreendem a evolução de uma população de inteiros binários, os quais são submetidos a transformações unitárias e binárias genéricas e a um processo de seleção (LOPES et al., 2006).

A utilização dos algoritmos evolutivos, de acordo com Deb (2001), expandiu-se nesses últimos anos, principalmente os algoritmos genéticos. Goldberg (1989) afirma que eles possuem uma característica que possibilita descobrir as soluções ótimas ou adequadas para um problema, sem

precisar usar informações extras, tais como o cálculo de derivadas das funções.

Estas técnicas citadas possuem metodologias e objetivos distintos, sendo que a estrutura básica dos AEs seguem um mesmo padrão. De acordo com Michalewicz (1996) e Brun (2000), esta composição pode ser da seguinte forma: um conjunto de soluções, denominado população, é criado aleatoriamente para se iniciar o algoritmo. Cada indivíduo desta população é a codificação de uma possível solução do problema e esta pode ser representada por um vetor, matriz ou valores binários, inteiros ou reais. Esta população é avaliada a cada iteração através da função de avaliação do indivíduo (função *fitness*), tratando o objetivo do problema a ser otimizado.

Depois disto, são selecionados alguns indivíduos de acordo com algum critério proposto no algoritmo. Por exemplo, em algoritmos tradicionais, os que possuem maior valor da função de avaliação têm maior probabilidade de serem selecionados e os escolhidos são submetidos a sofrerem alterações através de operadores genéticos, tais como *crossover* e mutação. Com isto, é gerado um novo conjunto de soluções candidatas que são avaliadas e geram novos descendentes. Dessa forma, um ciclo até que seja encontrada uma condição de parada satisfatória ou uma melhor solução seja encontrada. A Figura 3.1 a seguir, apresenta a referida estrutura (Michalewicz (1996), Brun (2000)).




Figura 3.1 - Diagrama da estrutura básica dos algoritmos da computação evolutiva.

3.1 Algoritmos Genéticos

3.1.1 Introdução

Decidir preços dos produtos elevando ao máximo o lucro das vendas, escolher o melhor caminho para ir ao trabalho ou escolher o melhor trajeto de ônibus que leve um maior número de passageiros numa distância menor percorrida são situações reais que devem decidir determinadas características de um sistema retirando dele o maior número possível de benefícios.

As ferramentas matemáticas permitem expressar estas situações na forma de funções. E, para descobrir quais valores devem ser escolhidos, para se atingir os pontos de máximo ou mínimo, foram desenvolvidos métodos de busca. A este processo dá-se o nome de otimização. Otimização

é o processo de ajuste das entradas ou das características de um dispositivo, processo matemático ou uma tentativa de encontrar o mínimo ou o máximo de um determinado problema. A entrada consiste de variáveis e o processo é conhecido como função custo (objetivo) (HAUPT; HAUPT, 2004).

Segundo Lopes (1999), estes métodos de busca podem ser feitos por métodos algébricos, numéricos ou heurísticos, através de uma busca no espaço multidimensional das variáveis do problema. Porém, quando tais métodos apresentam desempenho fraco ou até mesmo falhas devido à natureza da questão que envolve não-linearidade, descontinuidade, multimodalidade ou espaços de busca muito amplos, o método do AG mostra que é capaz de solucionar o problema devido ao seu alto grau de adaptabilidade, sua utilidade e a sua robustez.

Os AGs são técnicas estocásticas cujos métodos de pesquisa são baseados em dois fenômenos naturais: herança genética e luta Darwiniana pela sobrevivência (MICHALEWICZ, 1996).

3.1.2 Breve Histórico

Durante uma expedição científica ao redor do mundo em meados do século XIX, Charles Darwin observou e presenciou situações que levaram-no a pensar sobre uma nova teoria da evolução das espécies: a seleção natural. Em 1858, durante uma sessão da Academia Britânica de Ciências, Charles apresentou sua teoria da seleção natural. No ano seguinte, ele publica *On the Origin of Species by Means of Natural Selection*, apresentando a sua teoria por completa, apoiada nas evidências colhidas durante a sua expedição científica.

Segundo Darwin (1859), a seleção natural das espécies é um processo na qual os indivíduos mais adaptados possuem uma maior probabilidade de sobrevivência do que os menos adaptados. Os mais adaptados teriam um maior número de descendentes, provocando um aumento destes indivíduos em relação aos outros não adaptados na geração seguinte e assim, sucessivamente.

Esta teoria de Darwin é considerada como uma possível ferramenta de otimização para problemas de engenharia. Esses sistemas tinham como objetivo evoluir uma população de soluções candidatas a solucionar um determinado problema em estudo, usando operadores inspirados na variação genética e na seleção natural (KAZAY, 2001).

Com base na teoria evolutiva das espécies, o professor e pesquisador da Faculdade de Engenharia Elétrica e Computação da Universidade de *Michigan*, John Holland, juntamente com seus alunos e colegas de profissão, passaram a estudar formalmente os mecanismos de adaptação dos indivíduos com o objetivo de incorporá-los a ambientes computacionais. Na década de 60, ele propôs a construção de um algoritmo matemático para otimização em sistemas complexos o qual foi chamado de Algoritmo Genético (HOLLAND, 1992).

Adaptation in Natural and Artificial Systems é o título do livro que Holland publicou em 1975, na qual apresentou os AGs como uma abstração da evolução adaptativa, dando origem ao uso desta técnica para otimizar sistemas. Posteriormente, David. E. Goldberg, um dos alunos de Holland, depois de sua tese de doutorado, publicou um livro intitulado *Genetic Algorithms in Search, Optimization and Machine Learning* (GOLDBERG, 1989). Nele, Goldberg, após uma série de simulações, explicou mais detalhadamente o modo como os AGs eram utilizados. Esses livros ainda são considerados os mais importantes sobre os AGs e vêm sendo aplicados com sucesso nos mais diversos problemas complexos de otimização.

3.1.3 O algoritmo

Segundo Linden (2006), os AGs são técnicas heurísticas de otimização global e algoritmos de busca baseados nos mecanismos de seleção natural e genética. A palavra heurística é derivada do grego *heuriskein*, que significa descobrir ou encontrar.

Em otimização, heurística refere-se a um método de busca no qual são obtidas soluções aproximadas. Ela pode ser definida como sendo uma técnica de solução com baixo esforço computacional que é incapaz de garantir a viabilidade ou a otimalidade das soluções encontradas ou até mesmo ambas, especialmente nas ocasiões em que parte-se de soluções viáveis próximas do ponto ótimo.

Os AGs têm adquirido sucesso na aplicação de problemas complexos de otimização devido a sua ampla aplicabilidade em áreas tão distintas tais como: engenharias, ciências sociais, bioquímica, biologia, computação, desenho industrial, composição musical e pesquisa operacional (PO) (SIVANANDAM; DEEPA, 2008).

Correia (2002) afirma que para a PO, os AGs são empregados devido à quatro motivos: versa-

tilidade, robustez, simplicidade e eficiência. Versatilidade, porque a função *fitness* é calculada com clareza pelo programa e esta pode ser usada facilmente para diferentes funções, ou seja, o AG é apto a lidar com diferentes tipos de problema sem grandes mudanças no programa principal. É robusto o bastante para convergir para a região de máximo, já que não se pode garantir a obtenção do máximo global. O AG possui um entendimento simples do processo quanto de programação comparada aos demais métodos de otimização e é eficiente em determinar as possíveis soluções para problemas de complexidade média usando somente os seus operadores básicos.

Os algoritmos genéticos também possuem destaque entre os paradigmas da computação evolucionária. Segundo Torres (2003), eles englobam todos os conceitos da computação evolutiva de forma natural e simples. Enquanto outros métodos de otimização possuem problemas em fornecer as soluções admissíveis com relação aos recursos utilizados (computadores de pequeno porte) e a exatidão, os AGs não. Eles permitem sofrer inúmeras modificações em sua implementação e aceitam facilmente a hibridização com técnicas que não estejam relacionadas com a CE.

Como já citado, mesmo com abordagens distintas e desenvolvidas de forma independente, a estrutura de funcionamento de um algoritmo genético e de outros algoritmos evolutivos são idênticos (MICHALEWICZ, 1996).

3.1.4 Terminologia dos AGs

Os algoritmos genéticos emprestam termos da Biologia para a sua concepção, especialmente na área de evolução. De acordo com Pacheco et al. (2001), Filho (2005), Lopes (1999), Santos (2001), Takahashi (2004), Miranda (2007) e Reis e Akutsu (2002), os genes são os blocos construtores nos AGs. Estes são uma codificação dos parâmetros de otimização. A população inicial, no AG, é um conjunto de possíveis soluções e esta é formada por um conjunto finito de cromossomos. É a partir dela que o AG irá evoluir para um melhor conjunto de soluções do problema. Cada indivíduo desta população é representado por um único cromossomo o qual contém a codificação (conjunto de genes) de uma possível solução do problema (fenótipo). No AG, os cromossomos são uma cadeia de caracteres que representam alguma informação relativa às variáveis de decisão do problema em estudo. O cromossomo é formado por um conjunto de genes. São esses genes que

possuem os parâmetros a serem otimizados pelo AG.

Estes parâmetros podem ser binários, reais ou inteiros. No caso da codificação ser binária, os genes são formados por alelos (*bits*). São estes alelos que determinam as características diferentes dos cromossomos. Operações genéticas são as que os cromossomos são submetidos e envolvem avaliação, seleção, recombinação(*crossover*) e mutação. O número de iterações que o AG executa é chamado de geração ou gerações.

Os pais são formados por pares de cromossomos que, combinados, geram novos cromossomos filhos, ou seja, novas possíveis soluções para serem avaliadas. Cada indivíduo deve possuir uma função de adaptação, também conhecida como função *fitness*. No AG, ela é conhecida como função de avaliação do problema.

3.1.5 Características dos AGs

De acordo com Linden (2008), os AGs podem ser considerados técnicas probabilísticas, pois a cada execução do algoritmo pode-se encontrar soluções distintas. Isso ocorre, porque possui um mesmo conjunto de parâmetros e população inicial. Ele ainda afirma que o AG utiliza uma busca estruturada e paralela, mas aleatória, em direção aos pontos de maximização ou minimização da função objetivo.

O elevado desempenho nos resultados e a simplicidade de seu manuseio tornaram o algoritmo genético um método atrativo de ser utilizado (BIELLI et al., 2002).

É notório que os AGs estão sendo utilizados com mais frequência na solução de funções de otimização devido à sua eficiência. No entanto, nem sempre os resultados podem ser satisfatórios ou o problema não está adequado para o uso de suas técnicas. Por isso, é recomendável que se estude o problema a ser resolvido, antes de se tentar utilizá-lo, levantando características relativas deste. Dentre elas estão o espaço de busca das possíveis soluções (busca codificada), que devem estar delimitados por um intervalo, uma função de adaptabilidade, que avalie as soluções e classifique-as indicando quão boa ou ruim é uma determinada solução, e a mesma deve estar codificada para que a sua implementação não gere dificuldade.

Alguns autores afirmam que o algoritmo proposto por Holland pode ser descrito, sucinta-

mente, em seis passos (SANTOS; OHISHI, 2004):

1. Inicie-se uma população de tamanho k com cromossomos gerados, aleatoriamente;
2. Para cada cromossomo é avaliado a sua função *fitness*;
3. Através do cruzamento dos cromossomos selecionados, criam-se outros novos e depois são aplicados os operadores genéticos (*crossover* e *mutação*);
4. Mantendo-se o mesmo número de k indivíduos, são eliminadas as soluções da população antiga de modo a ter espaço para os novos indivíduos;
5. Aplique-se a função de *fitness* nestes novos cromossomos e insira-os na população;
6. Por fim, se o critério de parada for atendido, retorne o cromossomo com a melhor função *fitness*; se isto não ocorre, volte ao terceiro passo.

À medida que as gerações forem ocorrendo, esta simulação produzirá indivíduos melhores adaptados, isto é, essa função será a de melhor valor com um alto grau de adequação ao problema proposto. De forma bem simplificada, a Figura 3.2 abaixo representa uma estrutura de implementação do AG.




Figura 3.2 - Fluxo da implementação do AG.
Fonte:Elaboração própria.

Lopes et al. (2005) alegam que os AGs têm sido utilizados, frequentemente, com outras técnicas de busca e otimização mais convencionais, tais como *branch-and-bound*, busca tabu ou ainda *simulated annealing*. Dessa união é explorado o melhor que cada técnica é capaz de oferecer. Enquanto o AG é direcionado a uma busca global percorrendo, paralelamente, um grande espaço de busca. Os outros métodos exploram regiões específicas do mesmo espaço, promovendo uma busca local sequencial (AARTS; KORST., 1989).

3.1.6 Algoritmo Genético Básico

Segundo Sivanandam e Deepa (2008), a estrutura básica de funcionamento do algoritmo genético é simples e esse foi construído de forma que as informações referentes a um sistema pudessem ser codificados. O AG básico é composto por três operações básicas: seleção, *crossover* (recombinação) e mutação.

O funcionamento desta estrutura é explicado por Goldberg (1989), assim como a maneira de realização de cada fase. Primeiramente, é gerada uma população de forma aleatória. Cada componente ou indivíduo dessa população é chamado de cromossomo. A codificação desses cromossomos (indivíduo) e a sua representatividade adequada do espaço de busca são requisitos importantes para essa etapa, pois permite a aplicação do AG em problemas reais e uma manipulação eficiente dos operadores genéticos. A próxima fase é representada pela avaliação dos indivíduos no qual é aferida uma aptidão a cada solução do problema, através da função *fitness*. Baseado nesse cálculo, um operador de seleção atua escolhendo os melhores indivíduos da população, enquanto que os outros são descartados. Os selecionados são submetidos a operadores genéticos gerando assim, descendentes para a próxima geração. Por fim, esta nova população é avaliada como a original. Esse processo se repete até que uma condição de parada seja atendida ou até encontrar uma solução satisfatória.

A seguir é representado um pseudocódigo de um AG básico, modificado de Goldberg (1989), contendo os passos presentes dentro do processo.

- 1: Início
- 2: $t \leftarrow 0$
- 3: Criar população inicial $P(t)$
- 4: Calcular os valores de $P(t)$, ou seja, Avaliar $P(t)$
- 5: **Enquanto** a condição de **parada** não seja satisfeito **faça**
- 6: Início
- 7: $t \leftarrow t + 1$
- 8: Reproduzir $C(t)$ de $P(t - 1)$
- 9: Cruzar e mutar os indivíduos de $C(t)$
- 10: Formar $C'(t)$
- 11: Selecionar Substitutos de $P(t)$ em $C'(t)$ e $P(t - 1)$

12: **Fim**

13: Fim

De acordo com pseudocódigo acima, alguns autores (LOPES et al., 2005), (SIVANANDAM; DEEPA, 2008), (MIRANDA, 2007) e (SANTOS; OHISHI, 2004) a descrevem da seguinte forma: durante a iteração t (geração), uma população $P(t) = \{I_1^1, \dots, I_n^1\}$ é gerada aleatoriamente, contendo as soluções potenciais representadas por cromossomos ou indivíduos (vetor, matriz, valores binários, inteiros ou reais). Em seguida, cada solução é avaliada de acordo com o valor de sua função *fitness*. Com algum operador de seleção, que serão explicados posteriormente, os indivíduos mais aptos são selecionados para compor uma nova população $C(t)$ de iteração $t + 1$. Nessa iteração os indivíduos da nova população sofrem alterações por meio de recombinação e mutação, gerando filhos ou um novo conjunto de soluções $C'(t)$. Depois, esses filhos competem com seus pais ($P(t - 1)$) para criar uma nova população $P(t) = \{I_1^2, \dots, I_n^2\}$. Esse processo é então repetido até que um número pré-definido de iterações seja atingido ou até que o nível de adaptação esperado seja obtido.

3.1.7 Elementos dos Algoritmos Genéticos

Representação das variáveis

Como já dito, os AGs emprestam alguns termos da biologia para a sua concepção. Todos os seres humanos possuem estruturas que armazenam um conjunto de instruções de como será o indivíduo. Essa estrutura recebe o nome de cromossomos.

Cada indivíduo, no AG, é uma possível solução do problema, isto é, ele é um ponto que está disposto dentro do espaço de busca da solução ótima. Segundo Lacerda e Carvalho (1999), o cromossomo é uma estrutura de dados que também representa uma possível solução do problema a ser otimizado. Cada cromossomo é composto por cadeias de genes (*strings*) e esses são compostos por alelos. São eles que dão valor aos genes (BIELLI et al., 2002). No AG, dependendo do tipo do problema e do que se deseja manipular geneticamente a variável do cromossomo pode ser,

diferentemente representada.

De acordo com Pacheco (1999), os principais tipos de representação das variáveis são os valores binários, os reais ou inteiros, permutação de símbolos e símbolos repetidos. Michalewicz (1996) afirma que no funcionamento do AG somente é considerado um cromossomo por indivíduos, denominado cromossomos haplóides.

Cada solução do problema, cromossomo ou indivíduo (I), pode ser representado da seguinte forma:

$$I = [k_1 \ k_2 \ \dots \ k_{nvar}]$$

onde $nvar$ é o número de variáveis que cada indivíduo possui e $k_1 \ k_2 \ \dots \ k_{nvar}$ representam as variáveis (genes) que o formam e caracterizam a solução do problema.

A população P pode ser reproduzida por uma matriz

$$P^n = \begin{bmatrix} k_1^{n,1} & k_2^{n,1} & \dots & k_{nvar}^{n,1} \\ k_1^{n,2} & k_2^{n,2} & \dots & k_{nvar}^{n,2} \\ \vdots & \vdots & \vdots & \vdots \\ k_1^{n,npop} & k_2^{n,npop} & \dots & k_{nvar}^{n,npop} \end{bmatrix}$$

onde $npop$ é o número de indivíduos da população e n indica a geração corrente. Definindo-se os termos da população e os indivíduos, bem como a representação destes, pode-se passar à codificação destas variáveis.

Codificação das variáveis

Cada indivíduo é codificado por um conjunto de parâmetros (genes). A escolha da codificação utilizada no desenvolvimento do algoritmo genético deve ser considerada como um dos primeiros aspectos lembrados, pois ela é fundamental para o desempenho nas quais as vantagens e desvantagens serão analisadas com vista à aplicação desejada do problema a ser resolvido.

Os genes podem assumir valores binários, inteiros ou reais. O presente trabalho abordará a codificação binária e a codificação real.

- Codificação Binária

A codificação binária ou clássica foi a primeira a ser explorada devido à sua identidade direta com a genética natural. Essa técnica constrói a solução a ser avaliada pelo problema, ou seja, os cromossomos componentes do AG assumem necessariamente forma de cadeias binárias, constituídos por uma sequência de 0 e 1.

Srinivas e Patnaik (1994), Goldberg (1989), Houck et al. (1996) e Herrera et al. (1998) afirmam que o melhor método para a codificação das variáveis no AG é a binária devido a dois motivos. Primeiro pela simplicidade de sua utilização e manuseio na implementação e pelo pequeno número de parâmetros que o cromossomo possuirá. Pois quanto menor esse for, maior serão os esquemas processados simultaneamente e, com isto o AG será mais eficiente. Sendo assim, os operadores genéticos irão atuar com mais eficiência nos cromossomos.

No algoritmo genético clássico proposto por Holland (1992), a codificação dos indivíduos candidatos foi estabelecida por meio de arranjos binários de tamanho fixo. Entretanto, existem algumas dificuldades em trabalhar com este tipo de codificação.

Em problemas numéricos de elevada dimensionalidade no qual solicitada uma alta precisão, a representação binária não apresenta um desempenho satisfatório. Ao usar as cadeias binárias em um problema de domínio suficientemente e amplo, a necessidade de se conseguir uma solução ótima é relativamente baixa devido à dificuldade de se garantir este domínio (MICHALEWICZ, 1996).

Segundo Herrera et al. (1998), a necessidade de calcular o valor decimal da cadeia binária, acarreta um maior tempo em problemas que necessitam de uma boa precisão, pois esta implica num maior número de genes, aumentando o tamanho do cromossomo. Diferente da técnica clássica, apresentada por Holland, outras técnicas de codificação dos cromossomos foram surgindo devido às dificuldades encontradas ao usá-las. Uma dessas técnicas é conhecida como Codificação Real ou Ponto Flutuante.

- Codificação Real

Como o próprio nome diz, os genes desta codificação representam um valor real. Michalewicz (1996) afirma que esta codificação é útil para a otimização de problemas que possuem variáveis contínuas e para quando deseja-se trabalhar com uma precisão numérica boa.

Avila (2002) e Herrera et al. (1998) alegam que esta alternativa de codificação apresenta soluções muito próximas da formulação natural do problema em estudo, não existindo diferença entre o genótipo (codificação) e o fenótipo (espaço de busca). Eles também afirmam que é desnecessário colocar em prática a codificação/decodificação das variáveis para a avaliação da função de aptidão, porque os cromossomos gerados são menores, acarretando um mínimo consumo de tempo no processamento computacional do algoritmo.

A codificação real possui uma facilidade em usar os operadores de recombinação e de mutação com alterações nos parâmetros para obter-se uma melhor solução do problema. De acordo com Herrera et al. (1998), ela possibilita trabalhar com problemas de grandes domínios para as variáveis, ao contrário da codificação binária, em que o aumento do domínio pode expressar sacrifício da precisão.

Dependendo do objetivo a ser alcançando na otimização, alguns autores têm obtido um melhor desempenho com a representação real do que com a binária. Por isso, a escolha da codificação na elaboração do AG é uma etapa muito importante, pois efeitos indesejáveis podem surgir com a opção errada.

Espaço de Busca

O espaço de busca é conjunto de soluções factíveis associados a um valor de adequação ao problema. Essa solução pode ser um ponto de máximo ou mínimo dentro do espaço de busca. Em relação ao AG, este valor de adequação é obtido pela função de adaptação.

Matematicamente, o espaço de busca pode ser representado por equações ou inequações que restringem o domínio da solução do problema. Pode ser escrito da seguinte forma:

$$\max \quad f(x) = ax^2 + bx + c \quad (3.1)$$

$$\text{s.a.} \quad h(x) = 0 \quad (3.2)$$

$$g(x) \leq 0 \quad (3.3)$$

$$x \in \alpha \quad (3.4)$$

Esse problema busca encontrar um x ótimo, um ponto de máximo, que pertença ao espaço de busca descrito pelas Restrições 3.2, 3.3 e 3.4, maximizando a função objetivo(Equação 3.1).

O AG será usado para percorrer todo esse espaço de busca tentando encontrar a melhor solução.

3.1.8 Parâmetros do AGs

Existem outros parâmetros que influenciam no desempenho do AG como o tamanho da população, o número de gerações e as taxas de probabilidade de *crossover* e mutação.

De acordo com vários estudos, tais como Jong (1975), Goldberg (1989), Alander (1992), Reeves (1993) e Michalewicz (1996), o tamanho da população afeta o desempenho global e a eficiência do AG por estarem relacionados com o tamanho do espaço de busca. Se a população for pequena, o desempenho do AG pode ser insatisfatório, pois ele irá convergir mais facilmente para subótimos locais e não irá explorar suficientemente o espaço de busca.

Uma população grande requer um maior recurso computacional, sob pena de o AG consumir um período de tempo muito maior que o esperado, prevenindo a convergência prematura para soluções locais ao invés de globais do algoritmo.

Outro parâmetro que está relacionado com a população é a geração. A quantidade de indivíduos que serão selecionados para a próxima geração pode ser alta ou baixa, havendo uma perda de indivíduos com alta adaptabilidade em ambas escolhas (SILVA, 2001).

Em relação às taxas de probabilidade, no caso da mutação, ao adotar um valor baixo evita-se que certa posição no cromossomo fique inerte a um valor. Se for alto, a busca pela solução ótima do problema torna-se aleatória. No caso do *crossover*, quanto maior for esta taxa, mais novas estruturas serão introduzidas na população, podendo haver perdas de indivíduos de alta aptidão. Se a taxa for baixa, a evolução da população irá paralisar, podendo também convergir para um ótimo local. Na maioria da literatura os valores encontrados estão na faixa de 60% a 65% para a probabilidade de *crossover* entre 0,1% e 5% para a probabilidade de mutação (G., 2007; FILHO, 2006).

3.1.9 População Inicial

O primeiro passo para a implementação de um AG é a geração da população inicial. Como já dito, cada indivíduo dessa população é uma possível solução do problema e esta é gerada de forma aleatória para a maioria dos problemas. Entretanto, dependendo da aplicação do problema, podem existir formas heurísticas de selecionar indivíduos mais favoráveis para formar a população (LACERDA; CARVALHO, 1999; RUDOLF; BAYRLEITHNER, 1999).

Em geral, é importante que essa população inicial esteja muito bem dispersa pelo espaço de busca e que estes indivíduos possam ter uma boa diversidade genética, pois o AG necessita de uma grande diversidade de combinações para ter um bom funcionamento (GOLDBERG, 1989).

3.1.10 Função de Adaptabilidade ou *Fitness*

Os AGs promovem uma forma de mapear a representação do indivíduo em um valor numérico associado ao seu nível de adaptação. Esse valor é obtido pela função de adaptação ou função *fitness*. Tal função possui como responsabilidade avaliar e qualificar os indivíduos (cromossomos) indicando quais são os níveis de habilidade que esses possuem para sobreviver em relação ao ambiente.

Geralmente, este valor é determinado pelo cálculo da função objetivo, dependendo das especificações feitas pelo problema. Segundo Haupt e Haupt (2004) e Sivanandam e Deepa (2008), este valor não só indica que a possível solução é boa, mas também que a sua proximidade de ser o ideal.

De acordo com Santos (2001), essa função *fitness* deve obter valores que, ao serem retornados para o problema, não determine uma busca cega. Ao longo de sucessivas amostragens do processo do AG, deve ser fornecido indicações sobre a localização da solução ótima, pois em uma busca cega, encontra-lá é uma questão de sorte.

Se o problema a ser otimizado estiver trabalhando com a codificação binária é necessário que seus valores sejam convertidos em valores numéricos para obter o valor da função *fitness*. Na codificação real não existe essa necessidade.

3.1.11 Operadores Genéticos

Os operadores genéticos desempenham um papel importante no algoritmo genético. O objetivo destes são buscar melhorar a aptidão dos indivíduos através de sucessivas gerações. No AG eles são imprescindíveis devido ao fato de diversificar a população e manter as características de adaptação adquiridas pelas gerações anteriores. Seleção, recombinação e mutação são os operadores que, na maioria dos casos, o AG utiliza durante sua implementação.

Seleção

Depois de decidir sobre a codificação, o próximo passo é decidir como realizar a seleção dos indivíduos. Segundo Rudolf e Bayrleithner (1999) e Deb (2001), a seleção é uma operação do qual são selecionados alguns indivíduos da população para gerar outros via operações de recombinação e mutação. Seu objetivo principal é copiar boas soluções, eliminando aquelas de baixa aptidão.

Linden (2008) afirma que a seleção é um método que escolhe aleatoriamente os cromossomos de acordo com sua função de avaliação. Quanto maior for esta função, mais chance o indivíduo possui de ser selecionado. Existem diversos tipos de operadores de seleção, separados em grupos, em relação à forma que a seleção é feita. Estes grupos são formados pelos operadores de seleção determinística e estocástica.

Na seleção determinística, a regra de seleção é simples: ela ordena os indivíduos segundo os seus respectivos *fitness* e, deterministicamente, os melhores são escolhidos. Na seleção estocástica, os indivíduos são associados a uma probabilidade de seleção proporcional aos seus *fitness*. Com isso, a escolha dos indivíduos é feita de acordo com essa distribuição de probabilidade que cada um está relacionado.

Segundo Resende (2003), os métodos de seleção que possuem maior aceitação são: Roleta, Torneio e *Ranking*. Escobar (2007) alega que é preciso observar quais desses métodos se adaptam melhor a estrutura do algoritmo.

- Roleta

Este método de seleção denominado *Roulette Wheel* ou Roleta foi proposto por Goldberg (1989) e ele atribui a cada indivíduo uma probabilidade que está diretamente proporcional ao valor de *fitness* em relação ao somatório do *fitness* de todos os elementos da população.

Esta técnica permite a indivíduos que possuem um maior valor da função, mais aptos de cada geração, terem uma probabilidade maior de serem selecionados, devido a sua maior área na roleta. Para um melhor entendimento, a Figura 3.3 mostra 5 cromossomos cujas aptidões são dadas pela conversão de binário para decimal.




Figura 3.3 - Exemplo de *Roulette Wheel* com 5 indivíduos representados pela codificação binária juntamente com seus valores da função de aptidão.

Fonte:Elaboração própria.

A roleta pode ser girada quantas vezes forem necessárias para obter um número par de indivíduos requeridos para os demais operadores de recombinação e mutação, dependendo do problema a ser otimizado.

Entretanto, este método possui algumas dificuldades. Dentre elas, pode-se destacar a eliminação do melhor indivíduo durante o processo, pois a sua probabilidade de ser selecionado, apesar de ser alta, não é igual a 1. Visto que isso não é interessante ocorrer, criou-se uma estratégia que consiste em manter sempre o melhor indivíduo na próxima geração. Esta estratégia é conhecida como Seleção Elitista.

Seleção Elitista é uma técnica que consiste em manter pelo menos uma cópia do melhor indivíduo para a nova população evitando a sua perda com o passar das gerações (FOGEL, 1994; MICHALEWICZ, 1996; JONG, 1975; SZUVOVIVSK, 2008).

- Torneio

Um grupo de indivíduos de tamanho q da população é escolhido aleatoriamente. Esse

grupo participa de um torneio que o indivíduo vencedor é escolhido. Muitas vezes, neste tipo de seleção, existe uma disputa entre dois indivíduos e o que possui o melhor valor de *fitness* é escolhido para compor a próxima geração. O processo é repetido várias vezes até obter-se uma nova população.

- *Ranking*

Outro mecanismo de seleção utilizado é o baseado em *rank* (BACK et al., 1997(a)). Inicialmente, ele ordena os indivíduos conforme o valor de seu *fitness* e a utiliza para definir e associar um valor de probabilidade de seleção a cada um.

Para um melhor entendimento deste método, observe as Figuras 3.4 e 3.5 que demonstra como fica a situação antes e depois.




Figura 3.4 - Situação antes do *ranking*, ou seja, gráfico do *fitness*.




Figura 3.5 - Situação depois do *ranking*, ou seja, gráfico do número de ordem.

Pode-se perceber que todos os indivíduos, com o operador baseado em *ranking*, possuem chances semelhantes de serem selecionados. Entretanto, este método pode levar o algoritmo a uma convergência mais lenta devido ao *fitness* do melhor indivíduo não se diferenciar dos demais.

***Crossover* ou Recombinação**

Nos sistemas biológicos, a recombinação ou *crossover* é um processo complexo que ocorre entre dois cromossomos. Nos AGs, segundo [Larsen \(2002\)](#), a operação genética dele consiste em misturar materiais genéticos de dois indivíduos conhecidos como pais, obtidos na fase de seleção, produzindo dois novos indivíduos, conhecidos como filhos que herdam as características genéticas de seus progenitores. Este método possibilita propagar as características positivas dos indivíduos mais aptos, através da troca de informações entre diferentes soluções candidatas, para originar outras novas possíveis soluções.

A seguir, são apresentados os principais tipos operadores de *crossover* utilizados no AG.

1. *Crossover* com um ponto

Este operador é o mais fácil de implementar e o mais simples. Segundo [Holland \(1975\)](#), são escolhidos dois indivíduos de forma aleatória. Estes pais escolhidos irão gerar seus filhos, através da troca de informações contidas em seu cromossomo.

Depois, novamente, de forma aleatória, seleciona-se um ponto de corte nesses cromossomos pais indicando que após este ponto, esta fragmentação do seu material genético irá ser trocado.

Com isso, é feita a troca entre os pais, gerando dois novos descendentes (filhos). Cada um deles possuirá informações cromossômicas dos pais, como mostrado na [Figura 3.6](#).




Figura 3.6 - Exemplo de cruzamento com 1 ponto, aplicado à codificação binária.

2. *Crossover* com dois pontos

O funcionamento do *crossover* com dois pontos é similar ao de um ponto, ou seja, são selecionados dois pontos de corte nos cromossomos pais. Depois é feita a troca do material genético, sendo que o primeiro cromossomo filho será formado pela primeira e terceira parte de um dos cromossomos pais e o segundo filho pelas partes restantes. A representação desse processo é apresentada na figura 3.7.




Figura 3.7 - Exemplo de cruzamento com 2 pontos, aplicado à codificação binária.

Segundo Michalewicz (1996), os operadores descritos até aqui podem ser usados para quase todos os tipos de codificação. Entretanto, alguns modelos foram feitos especialmente para a codificação real. Um exemplo específico é o *crossover* aritmético.

Esse operador atua nos cromossomos pais fazendo uma combinação linear entre os genes que ocupam a mesma posição nos dois, ou seja, é feita uma fusão de dois vetores. Suponhamos que A_{m_1} e A_{m_2} sejam dois indivíduos selecionados. Os filhos gerados por estes cromossomos serão da seguinte forma:

$$B_{n_1} = \alpha A_{m_1} + (1 - \alpha) A_{m_2} \text{ e} \quad (3.5)$$

$$B_{n_2} = (1 - \alpha) A_{m_1} + \alpha A_{m_2}. \quad (3.6)$$

onde α é um número aleatório pertencente ao intervalo $[0,1]$.

Este operador também é adequado para problemas de otimização numérica com restrições em que a região factível é convexa. Isto irá garantir que o *crossover* não irá gerar indivíduos inválidos para o problema, já que a combinação convexa de A_{m_1} e A_{m_2} será também factível (MICHALEWICZ; SCHOENAEUR, 1996).

Mutação

Dependendo da escolha da população inicial, esta pode ou não ter uma variedade de indivíduos suficientemente para garantir que o AG verifique todo o espaço de busca do problema. Sendo assim, ele pode vir a convergir para soluções que não são próximas da ótima.

A introdução da mutação nos indivíduos pode minimizar o problema promovendo alterações no código genético dos cromossomos. Dependendo da taxa de mutação, a mesma irá direcionar uma pesquisa no espaço de busca para fora da região na qual a solução não é boa, sujeito a encontrar um falso ótimo (BIELLI et al., 2002).

No AG clássico desenvolvido por Holland (1992), que utiliza a codificação binária, o operador de mutação somente faz a troca do valor do gene selecionado, ou seja, muda o valor 1 para 0 e vice-versa.

Já em casos que utilizam a codificação real, há alguns operadores de mutação específicos para isto, tais como: a mutação gaussiana e a mutação não uniforme, segundo Michalewicz e Schoenauer (1996); e a mutação uniforme, segundo Michalewicz (1996).

Optou-se pelo uso do operador de inversão como forma de mutação nessa dissertação. O mesmo seleciona dois genes do cromossomo aleatoriamente e com isso é feita a inversão das posições. Por exemplo, seja o vetor [150 **142** 125 143 **135** 132] e os genes 142 e 135 escolhidos aleatoriamente e marcados em negrito. Após a mutação, o novo vetor do indivíduo passa a ser [150 **135** 125 143 **142** 132].

3.1.12 Critério de Parada do AG

Após a descrição dos componentes dos operadores genéticos, falta ainda mencionar condições de finalização do AG. O ideal seria prosseguir com o algoritmo até encontrar o máximo ou mínimo da função objetivo, mas somente é possível em problemas nos quais a solução já é conhecida. O AG seria um método que permitiria encontrá-la.

Nos problemas cujo o espaço de busca é muito amplo, não se é capaz de reconhecer o ótimo

global do problema devido à inviabilidade de se conhecer todas as possíveis soluções dentro do mesmo espaço. Desse modo, é necessário estabelecer critérios de parada para o AG. Ele irá proceder até que um destes critérios seja atendido.

De acordo Lacerda e Carvalho (1999), não existe um critério exato para determinar o fim do AG. Entretanto quando é adquirido fatores que levem o algoritmo a convergir, esta convergência seria um critério de parada.

Os critérios mais simples e mais frequentemente empregados no AG, segundo Pacheco et al. (2001), seriam estipular um número máximo de gerações e fixarem um determinado nível de diversidade da população e um tempo máximo de processamento. No primeiro caso, se esta última nova população gerada não obtiver aceitação de resolução do problema, o algoritmo deve ser reiniciado.

3.1.13 Diferenças e Vantagens dos AGs em relação a outros métodos de otimização

O princípio do AG é simples: imitar a genética e a seleção natural através de um programa computacional. Muitos autores destacam as vantagens e as diferenças que o AG possui em relação aos demais métodos de otimização.

De acordo com Goldberg (1989) e Sivanandam e Deepa (2008), eles se diferenciam, porque, primeiramente, o AG trabalha com uma codificação do conjunto de parâmetros do problema ao invés de utilizar os próprios parâmetros. Em outras palavras, é trabalhado com a codificação do conjunto de soluções candidatas a resolverem o problema e não com uma só solução.

Outra diferença seria que, enquanto todas as outras técnicas convencionais de otimização buscam um único ponto, o AG utiliza uma população de pontos (soluções) em paralelo, capacitando-os a pesquisar em espaços de busca ruidosos com vários pontos ótimos locais. Além disso, o AG usa as informações da função objetivo à respeito do problema, ao invés de informações de primeira ordem (derivadas).

E, finalmente, o AG utiliza regras de transição probabilísticas enquanto os outros métodos convencionais de otimização contínua operam com regras de transição determinísticas. Haupt e Haupt (2004) afirmam que todas estas vantagens de se utilizar o AG são intrigantes, e que, essas produzem resultados impressionantes quando o método tradicional de otimização falhar.

Segundo Reis e Akutsu (2002), uma dificuldade que pode ser encontrada ao empregar o AG, além de não possuir a garantia da determinação do ótimo global, é a falta de padronização em sua utilização, devido ao fato de que, cada problema a ser otimizado com sua exploração, em relação aos conceitos envolvidos, pode ser tratado de forma distinta na implementação.

Serão citadas algumas limitações e vantagens do AG descritos por Sivanandam e Deepa (2008):

- Limitações
 1. Possibilidade de ocorrer uma convergência prematura;
 2. O problema deve escolher diversos parâmetros como o tamanho da população inicial, as taxas de recombinação e mutação e o método de seleção;
 3. Não é possível usar gradientes;
 4. Não é muito eficaz em identificar o ótimo global dependendo do problema;
 5. A sua configuração não é tão simples.
- Vantagens
 1. Espaço de busca é mais amplo;
 2. Podem ser facilmente modificados e empregados para diferentes problemas de otimização;
 3. A descontinuidade pode estar presente na superfície de resposta que ela não causará efeito sobre o desempenho global do algoritmo;
 4. Executam muito bem em problemas de otimização de grande escala;
 5. São mais resistentes a tornarem-se presas em ótimos locais.

Há inúmeros artigos publicados em relação aos AGs tal fato deve-se à utilização que vem sendo feita por vários pesquisadores de diversas áreas ligadas aos problemas de situações reais. *Algoritmo Genético baseado no agendamento dos tratamentos de radioterapia para pacientes com câncer* foi o título de um artigo apresentado por Petrovic et al. (2009) na *Conference on Artificial Intelligence in Medicine - AIME 2009*. Esse artigo mostrou que um modelo multiobjetivo, baseado nos AGs, foi desenvolvido e aplicado a um problema de tratamento de radioterapia, em uma clínica no Reino Unido, chamada *Arden Cancer Center*. Este modelo tinha como objetivo minimizar o tempo de espera pelo paciente e do atraso médio de atendimento do primeiro paciente até o seu tratamento. Petrovic et al. (2009) demonstraram que, a falta de rapidez dos médicos na aprovação dos planos de saúde dos pacientes (tratamento), geram este grande impacto na espera. Com o AG,

ele conclui que, o tempo médio de espera e atrasos poderiam ser reduzidos em 35 e 20 minutos, respectivamente.

4 OTIMIZAÇÃO

4.1 Introdução

Muitos problemas científicos possuem possibilidades de serem formulados matematicamente, como problemas de otimização. Otimização, basicamente, refere-se a encontrar uma melhor solução para um determinado problema a ser resolvido dentro de um conjunto de possíveis soluções. Sobremaneira, descobrir uma ou mais combinações de fatores que proporcione o melhor desempenho possível do problema em questão. A otimização, de acordo com [Bennaton \(2001\)](#), é uma área que se nutre das ciências exatas, tecnológicas (computacional) e biológicas.

Segundo [Deb \(2001\)](#) e [Luenberger \(1986\)](#), os instrumentos necessários para se obter melhor esclarecimento da(s) solução(ões) ótima(s) obtida(s) nos problemas de otimização, são: a habilidade em modelos matemáticos e a boa capacidade de interpretação dos resultados no intuito de investigar se estas estão de acordo com os objetivos ou metas estabelecidas.

A concepção destas soluções ótimas nos problemas, por exemplo, de custo mínimo na fabricação de produtos ou na confiabilidade máxima de geração dos mesmos, revela a importância da prática dos métodos de otimização. Principalmente, em projetos de engenharia, em experimentos científicos e nas tomadas de decisão nos negócios. Esses métodos envolvem, além da modelagem computacional, uma ou mais funções objetivos a serem otimizadas. Quando o problema de otimização possui uma única função objetivo, a tarefa de encontrar a solução ótima é chamado de Otimização Mono-Objetivo. Se o problema abrange mais de uma função objetivo, com a incumbência de encontrar uma ou mais soluções ótimas, é conhecido com Otimização Multiobjetivo (MOOP, do inglês *Multiobjective optimization problem*).

Nas próximas Seções 4.2, 4.3 e 4.4, serão apresentadas definições e conceitos básicos sobre Otimização mono-objetivo e multiobjetivo e as suas diferenças, respectivamente.

4.2 Otimização Mono-Objetivo

Problemas com apenas uma função objetivo a ser otimizada é chamado de otimização mono-objetivo, como explicado, anteriormente. Sem perda de generalidade, este tipo de otimização possui um objetivo como apresentado a seguir:

$$\text{Min } F(x) \quad (4.1)$$

$$\text{s. a. } g_i(x) \leq 0 \quad (4.2)$$

$$h_j(x) = 0 \quad (4.3)$$

$$x \in \Omega \quad (4.4)$$

$$(4.5)$$

para $i = 1, \dots, m$ e $j = 1, \dots, p$, onde:

x	Vetor de decisão
$F(x)$	Vetor objetivo
$g_i(x)$	Restrição de desigualdade
$h_j(x)$	Restrição de igualdade
Ω	Espaço de decisões

Esse problema minimiza a função objetivo (Equação 4.1) em que x é vetor n-dimensional de variáveis de decisão pertencentes ao universo Ω . Este problema terá uma solução factível se as Restrições 4.2 e 4.3 forem atendidas.

4.3 Otimização Multiobjetivo

Como já foi dito, a otimização multiobjetivo consiste em maximizar ou minimizar, simultaneamente, um número de funções objetivo que satisfaça todas as restrições do problema.

Coello et al. (2007) e Deb (2001) afirmam que a otimização multiobjetivo resume-se no encontro de um vetor de decisão de variáveis que satisfaça as restrições e otimize a função vetorial, sendo que os elementos do mesmo representam as funções objetivos. Sem perda de generalidade, a minimização ou maximização de um problema multiobjetivo com k objetivos é definido da seguinte forma:

$$\text{Max } F(x) = (f_1(x), f_2(x), \dots, f_k(x)) \quad (4.6)$$

$$\text{s. a. } g_i(x) \geq 0 \quad (4.7)$$

$$h_j(x) = 0 \quad (4.8)$$

$$x \in \Omega \quad (4.9)$$

para $i = 1, \dots, m$ e $j = 1, \dots, p$, onde:

x	Vetor de decisão
$F(x)$	Vetor objetivo
$g_i(x)$	Restrição de desigualdade
$h_j(x)$	Restrição de igualdade
Ω	Espaço de decisões

Note que $x = (x_1, x_2, \dots, x_n)$ é um vetor n -dimensional de variáveis de decisão pertencentes a um único universo Ω . O mesmo será factível se as Restrições 4.7 e 4.8 forem saciadas e se esta pertencer ao espaço Ω . Segundo Deb (2001) e Michalewicz (1996), a maioria dos problemas reais de otimização envolvem múltiplas funções objetivo. Estas funções são consideradas conflitantes quando não existe uma única solução que seja ótima, simultaneamente, para todas as funções. Sendo assim impossível encontrar uma solução que otimize cada função.

Entretanto, existe um conjunto de soluções ótimas, no qual cada solução satisfaz o problema multiobjetivo sem ser dominado por qualquer outra solução. Sintetizando a questão, uma possível solução ótima é aquela que domina as outras quando seu valor é melhor em todos os objetivos. Este conjunto de soluções são encontrados através da Teoria da Otimilidade de Pareto (EHRGOTT, 2005), que será explicado mais detalhadamente na Seção 4.5 .

4.4 Diferenças entre otimização Mono-Objetivo e Multiobjetivo

É notório que haja certas diferenças entre os dois tipos de otimização. Deb (2001) afirma que há três importantes diferenças entre otimização multiobjetivo e mono-objetivo:

1. Primeiramente, a finalidade na otimização mono-objetivo é encontrar uma única solução ótima (máximo ou mínimo) enquanto que na otimização multiobjetivo pode existir mais de uma solução ótima. Portanto, achar o conjunto de soluções da Fronteira de Pareto é tão importante quanto preservar a diversidade neste conjunto.
2. Um problema de otimização multiobjetivo trabalha com dois espaços (variáveis e objetivos). Os problemas mono-objetivo trabalham somente com um único espaço de variáveis, já que este procura apenas uma solução no espaço de objetivos.
3. Os métodos tradicionais de otimização multiobjetivo estão baseados em uma função que pondera cada objetivo. Ele pode também tratar cada função objetivo separadamente, utilizando os demais como restrições. Dependendo das técnicas utilizadas, um problema multiobjetivo pode vir a ser convertido em um problema mono-objetivo.

Tomemos como exemplo um problema de otimização de dois objetivos, cada um correspondendo a uma solução ótima diferente. Este problema consiste na compra de um automóvel na qual existem quatro opções, que variam entre duas condições: conforto e preço. Se o comprador pretende sacrificar o custo mínimo em troca de conforto, ele não escolherá a solução 2, conforme a Figura 4.1, mas sim uma outra alternativa onde sua capacidade financeira esteja de acordo ao seu esperado padrão de conforto. Com isso, é possível notar que existem duas opções de compra (soluções 1 e 3), nas quais o ganho em um leva ao sacrifício do outro objetivo. As opções de compra 2 e 4 são consideradas ótimas sob a ótica que nenhuma delas é melhor que a outra em ambas as condições. Em síntese, nenhuma delas satisfaz em ambos os objetivos. Logo, essas duas soluções são conflitantes. Diante do impasse, conclui-se que não existe uma solução ótima simples. O que há são soluções que podem ser consideradas ótimas para o problema. O que foi apresentado é um exemplo da diferença entre otimização mono-objetivo e multiobjetivo.




Figura 4.1 - Exemplo que ilustra opções de compra de carro.

4.5 Pareto

Uma solução é dita ótima de Pareto se não existir nenhuma outra solução que a domine num espaço de solução. Essa otimalidade de Pareto fornece um conjunto de soluções nomeadas de soluções não dominadas. Esse conceito de dominância é usado na otimização de algoritmos evolucionários multiobjetivo. De acordo com Deb (2001), sejam dadas duas soluções quaisquer, x_1 e x_2 , pode-se afirmar que a solução x_1 domina a solução x_2 (matematicamente $x_1 \prec x_2$) se essas condições forem verdadeiras:

1. A solução x_1 não é pior que a solução x_2 , isto é, para todo $j = 1, \dots, n$, a função objetivo $f_j(x_1)$ não é pior que $f_j(x_2)$;
2. Se a solução x_1 é estritamente melhor que x_2 pelo menos em um objetivo, ou seja, $f_j(x_1)$ é melhor que $f_j(x_2)$ em um objetivo particular para todo $j = 1, \dots, n$.

Se essas condições forem satisfeitas, pode-se dizer que as duas soluções relacionam-se entre si das seguintes formas:

- x_2 é dominada por x_1 ;

- x_1 é não dominada por x_2 ;
- x_1 não é inferior que x_2 .

O conjunto de todas as soluções não dominadas definem a Fronteira de Pareto. O procedimento natural para a construção dessa fronteira é computar um número suficiente das soluções factíveis dentro do espaço Ω e seus correspondentes $f(\Omega)$ e, com isso, determinar os pontos não dominados. Na Figura 4.2 e 4.3 tem-se um exemplo de dominância de Pareto e a Fronteira de Pareto para feito de exemplo, respectivamente.




Figura 4.2 - Dominância de Pareto no espaço objetivo Ω .




Figura 4.3 - Fronteira de Pareto.

Observa-se que na Figura 4.2 existem 2 funções objetivos com 5 soluções de diferentes valores dentro do espaço de soluções. A função objetivo f_1 maximiza as soluções enquanto f_2 minimiza. Nesse caso, é muito difícil encontrar uma única solução ótima para ambas as funções ao mesmo tempo. Com isso, para investigar qual solução é a melhor entre quaisquer duas, usa-se o conceito de dominância. Por exemplo, ao comparar as soluções 1 e 2, note que a solução 1 é melhor que a 2 em relação à função objetivo f_1 e a solução 1 é também melhor que a 2 na função objetivo f_2 . Logo, como ambas as condições de dominância estão satisfeitas, é correto afirmar que a solução 1 domina a solução 2.

No caso das soluções 1 e 5, em relação à função objetivo f_1 , percebe-se que a solução 5 é melhor que a 1. Entretanto, quando comparadas em relação à função objetivo f_2 , a solução 5 não é pior, na verdade são iguais, que à 1. Assim sendo, nota-se que as condições de dominância também estão satisfeitas, logo é notório que a solução 5 domina a solução 1 e ela não-dominada por nenhuma outra. O mesmo acontece com as soluções 3 e 4, ou seja, essas não são dominadas por nenhuma outra solução.

Portanto, há um conjunto de soluções ótimas que é denominado por soluções não-dominadas 3, 4 e 5. Esse conjunto constitui a fronteira de Pareto (Figura 4.3). As outras soluções formam o conjunto das soluções dominadas. Segundo Coello et al. (2007) e Deb (2001), no conjunto das soluções não dominadas, qualquer par dessas soluções deve ser não dominada uma em relação a

outra. No conjunto das soluções dominadas, quaisquer delas devem ser dominadas por, no mínimo, uma solução do conjunto não dominado. De acordo com Deb (2001) e Konak et al. (2006), o objetivo final de um algoritmo de otimização multiobjetivo é identificar as soluções no conjunto ótimo de Pareto. Entretanto, em problemas nos quais este conjunto é muito grande, é praticamente impossível reconhecer todas as soluções.

Portanto, uma abordagem prática para problemas de otimização multiobjetivo é investigar um conjunto de soluções que represente, se possível, o conjunto ótimo de Pareto. Para isso, deve-se chegar a dois objetivos : primeiramente, o conjunto ótimo de Pareto "conhecido" deve ser o mais próximo possível do "verdadeiro", pois soluções muito distantes da fronteira de Pareto não são desejáveis. O ideal seria que esse conjunto "conhecido" seja um subconjunto do conjunto ótimo de Pareto. O segundo objetivo é encontrar um conjunto de soluções distribuídos uniformemente e diversificado ao longo da fronteira de Pareto. A fim de que essa diversidade aconteça, é necessário que o espaço de cobertura para elas seja o maior possível. Porém, em alguns problemas o fato não ocorre.

Zitzler e Thiele (1999) e Coello et al. (2007) afirmam que os algoritmos evolutivos são, particularmente, adequados para resolver os problemas de otimização multiobjetivo onde existem soluções conflitantes pois, eles são capazes de procurar por diversas soluções ótimas de Pareto simultaneamente de uma única vez, diferentemente de outras técnicas tradicionais. Eles também são menos suscetíveis com a forma ou com a continuidade da fronteira de Pareto, ou seja, podem lidar com fronteiras descontínuas ou côncavas, por exemplo.

4.6 Algoritmos Evolutivos (AE)

É notório que nos últimos anos, o uso dos AEs tem se expandido na aplicação de problemas de otimização multiobjetivo, em especial os AG. Simular modelos computacionais baseados nos princípios naturais evolutivos, com a finalidade de criar procedimentos de busca e otimização, é o principal papel desenvolvido pelos AE. Apesar de haver uma grande variedade de modelos computacionais, os AEs possuem, em comum, o conceito de simulação da evolução das espécies.

O potencial desses algoritmos, na resolução de problemas de otimização multiobjetivo, foi su-

gerido no final de 1960 por Rosenberg em sua tese de doutorado (ROSENBERG, 1967). A mesma teria sido levada a uma otimização multiobjetivo se Rosenberg tivesse solucionado o problema de acordo com o que havia proposto. Ele sugeriu usar várias propriedades em uma simulação genética e química de uma população de organismos unicelulares. Entretanto, ele só utilizou-se de apenas uma única propriedade em sua implementação. Por isso, a abordagem multiobjetivo não foi mostrada em sua tese. A primeira implementação de um AE multiobjetivo foi mostrada por David Schaffer, em 1984, em sua tese de doutorado (SCHAFFER, 1984). Ele propôs um modelo denominado *Vector Evaluated Genetic Algorithm* (VEGA), que consistia numa modificação dos AG para se poder avaliar cada função objetivo, separadamente. Um dos problemas desse modelo é que ele não obtém uma boa diversidade nas soluções da Fronteira de Pareto (DEB, 2001).

Além de VEGA, há vários métodos que podem ser usados para resolver problemas de otimização multiobjetivo, por exemplo, *Niched Pareto Genetic Algorithm* (NPGA), *Pareto-Archived Evolution Strategy* (PAES) e *Strength Pareto Evolutionary Algorithm* (SPEA). No presente estudo foi adotado a utilização do algoritmo SPEA.

4.6.1 *Strength Pareto Evolutionary Algorithm*

Eckart Zitzler e Lothar Thiele (ZITZLER; THIELE, 1998a) propuseram um algoritmo evolucionário elitista denominado *Strength Pareto Evolutionary Algorithm* (SPEA). Esse algoritmo baseia-se nos conceitos de dominância da Fronteira Ótima de Pareto ¹.

O pseudocódigo do SPEA é apresentado a seguir de acordo com Sbalzarini et al. (2000).

O SPEA inicia-se com a geração de uma população aleatória P de tamanho N e com a criação de uma população externa vazia P' com capacidade máxima de soluções não dominadas. Essas, a cada iteração t , são reproduzidas na população externa P' . Na mesma permanecem as melhores soluções não dominadas combinadas com as novas e as velhas. Se nesse conjunto existirem soluções dominadas, serão eliminadas. No decorrer das iterações, as soluções armazenadas podem ultrapassar o número máximo de soluções de $P'(t)$. Dessa forma, esse grupo pode ser reduzido através de um método chamado agrupamento.

¹Conceito já explicado da Seção 4.5

Algoritmo 4.1 Pseudo-código do SPEA

- 1: Gerar aleatoriamente uma população inicial $P(t)$ e criar um conjunto vazio externo $P'(t)$
 - 2: Avaliar função *fitness* de cada indivíduo em $P(t)$
 - 3: Copiar as soluções não dominadas de $P(t)$ para $P'(t)$
 - 4: Se o número de soluções não dominadas armazenadas em $P'(t)$ ultrapassar um número estabelecido N' então, eliminar este excedente através de agrupamento. Se não, manter $P(t)$ sem alterações.
 - 5: Avaliar os indivíduos de $P(t)$ e de $P'(t)$
 - 6: Selecionar indivíduos de $P(t)$ e $P'(t)$
 - 7: Aplicar cruzamento e/ou mutação nos indivíduos selecionados $P(t)$ e $P'(t)$, a fim de gerar uma nova população $P(t + 1)$
 - 8: Se o número máximo de gerações é atingido, então pare, senão volte para o Passo 2
 - 9: **Fim**
-

O método de agrupamento foi proposto por Zitzler e Thiele (1999) na qual calcula-se a distância entre dois conjuntos. Primeiramente, cada solução em $P(t)$ é separado em n grupos. Se dois desses possuírem uma menor distância entre si, esses são unidos para formarem um novo conjunto. O processo de união dos conjuntos continua até que o número máximo de soluções permitidas, no conjunto externo seja atingido, reduzindo a população.

A distância d estes dois grupos é calculada através da Fórmula 4.10.

$$d = \frac{1}{|c_j| \cdot |c_k|} \sum_{i_j \in c_j, i_k \in c_k} \|i_j - i_k\|, \quad (4.10)$$

onde i_j e i_k são duas soluções, c_j e c_k são grupos nos quais $i_j \in c_j$ e $i_k \in c_k$ e $\|\cdot\|$ é a métrica adotada para se calcular a distância entre duas soluções.

Logo, todas as outras soluções são excluídas e a solução com a distância média mínima em relação a outro grupo é mantida. Cada solução $i \in P'$ possui um real valor $s_i \in [0; 1)$ atribuído a elas, denominado *strength*. Este valor s_i é proporcional ao número de indivíduos $j \in P$ para cada $i \prec j$ e é definido através da Fórmula 4.11.

$$s_i = \frac{n}{N + 1} \quad (4.11)$$

onde n é a quantidade de soluções P que são dominados por i e N é o tamanho da população. As soluções não dominadas possuem $s_i = 0$.

A função *fitness* dos indivíduos $i \in P(f_i)$ são iguais a s_i . Porém, o valor da aptidão de um indivíduo j (f_j) da população P' é dada pela Equação 4.12

$$f_j = 1 + \sum_{i, i \succ j} s_i, \quad (4.12)$$

o que implica em $f_j \in [1, N)$.

O segundo termo da Equação 4.12 trata da soma dos valores s_i , das soluções não dominadas $i \in P'$ que dominam j . O valor mínimo do *fitness* f_j é 1, garantindo que os indivíduos de P' possuam uma maior probabilidade de serem selecionados para gerar descendentes, pois quanto menor esse valor, melhor é o *fitness*.

5 IMPLEMENTAÇÃO COMPUTACIONAL

A formulação matemática do problema de despacho para a programação da operação diária desenvolvida nessa dissertação é apresentada na Seção 5.2. Para maior clareza das equações descritas até o final deste capítulo, apresentam-se as variáveis utilizadas.

USB	UHE Sobradinho
ULG	UHE Luiz Gonzaga (Itaparica)
UAS	UHE Apolônio Sales (Moxotó)
UPA	Conjunto das UHE Paulo Afonso I, II e III
USQ	UHE Paulo Afonso IV
UXG	UHE Xingó
i	Índice da usina
k	Índice da UG
j	Índice do período de tempo
n_i	Número de UG em uma UHE i
UHE	Conjunto de usinas USB, ULG, USQ e UXG
h_m	Nível a montante da usina i (m)
h_t	Nível a jusante da usina i (m)
h_h	Perda por elevação do canal de fuga (m)
Q_i	Vazão média que a usina i deve manter ao longo do dia (m^3/s)
q_i^j	Vazão turbinada pela usina i no período j (m^3/s)
p_i^j	Potência gerada pela usina i no período j (MW)
x_i^j	Nível do reservatório da usina i no período j (m)
x_i^0	Nível do reservatório da usina i no último período do dia anterior (m)
ρ_i	Função de produtividade da usina i
$\bar{\rho}_i$	Produtividade média da usina i
η_i	Função de eficiência da usina i

$\overline{G}$	Geração das UHE UPA e UAS (MW)
d^j	Demanda total menos a geração das quatro usinas de <i>UHE</i> no período <i>j</i> (MW)
$y_{i,k}^j$	Variável binária - indica se a UG <i>k</i> da UHE <i>i</i> no período <i>j</i> é despachada
$p_{i,k}^j$	Potência gerada pela UG <i>k</i> da usina <i>i</i> período <i>j</i> (MW)
$p_{i,k}^{j,min}$	Potência mínima da UG <i>k</i> da usina <i>i</i> período <i>j</i> (MW)
$p_{i,k}^{j,max}$	Potência máxima da UG <i>k</i> da usina <i>i</i> período <i>j</i> (MW)

No presente capítulo é apresentado um modelo matemático para o problema de programação da operação diária das UHES da cascata do Médio São Francisco. A Figura 5.1 a ilustra.




Figura 5.1 - Cascata de UHES do Rio São Francisco.

No horizonte de programação diária, pode-se considerar que a operação hidráulica de USB independentemente das outras UHES do COMPLEXO de Paulo Afonso, incluindo ULG, UPA, USQ, UAS e UXG. O fato ocorre devido ao tempo de viagem da água que sai de USB até ULG de, aproximadamente quatro dias. Dessa maneira, a afluência que chegará à ULG no dia seguinte, é consequência da operação de USB de quatro dias atrás. Do ponto de vista elétrico, existe um acoplamento, pois a USB juntamente com as do COMPLEXO irão atender o mercado diário previsto.

Para que o modelo proposto seja de fácil manipulação e rápida solução, procurou-se fazer uma representação menos detalhada da operação hidráulica da cascata, mas suficiente para que a solução obtida atenda a todas suas restrições operativas. Primeiramente, foi implementado uma relação direta da vazão defluente de uma UHE apresentada com a defluência da UHE à montante, descontando o tempo de viagem da água. Essa relação provocou matematicamente a criação de uma restrição para cada usina a cada intervalo de tempo. O acoplamento hidráulico entre as UHES do

COMPLEXO foi considerado em termos diários assegurando, assim, que haja uma coordenação hidráulica entre as usinas ao longo da operação diária e que a UHE à montante realize uma defluência suficiente para que a UHE, imediatamente, à jusante possa atender a sua curva de geração.

5.1 Condições de Contorno

Foram consideradas algumas hipóteses que definem as condições que a programação diária da cascata deve atender, denominadas de Condições de Contorno. No sentido de trabalhar com uma formulação mais simplificada, o modelo supõe conhecida as seguintes condições:

1. Presumi-se conhecida a vazão afluyente (média diária) a ser recebida pelas USB e ULG no próximo dia, a curva de carga diária e a disponibilidade de máquinas.
2. O armazenamento (ou deplecionamento de reservatório) na cascata será realizado somente nos reservatórios de USB e ULG. As demais UHEs devem terminar o dia com os seus reservatórios em um estado aproximadamente igual ao do início do dia.
3. Toda a defluência diária da ULG irá atravessar todo o COMPLEXO, de modo que, os reservatórios de UAS, USQ e UXG devam terminar no mesmo estado do início do dia. Com isso, a defluência diária de UAS mais a defluência diária de USQ devem ser iguais à defluência diária de ULG. Por sua vez, a defluência diária de UPA mais a defluência diária de USQ devem também ser iguais à defluência diária de ULG. Não diferente, a defluência diária de UXG também deve ser igual à defluência diária de ULG.
4. Como USB e ULG são consideradas hidraulicamente independentes no horizonte diário, então a defluência média diária da USB ($\bar{D}_{USB}$) não precisa ser necessariamente igual à defluência média diária da ULG ($\bar{D}_{ULG}$).

Em função das condições acima, o decisor precisa fixar outras condições para a implementação do modelo.

1. Em função da vazão afluyente, da curva de carga diária a ser atendida e da disponibilidade de máquinas, o decisor estabelece qual deve ser a defluência média diária na USB e na ULG. Aproximadamente, a vazão turbinada média que deve atravessar toda a cascata do São Francisco é calculada na Equação 5.1, na qual $\bar{d}$ é a demanda média a ser

atendida pelas usinas e $\bar{\rho}_{\text{cascata}}$ é a produtividade média da Cascata:

$$\bar{q}_{\text{cascata}} = \frac{\bar{d}}{\bar{\rho}_{\text{cascata}}} \quad (5.1)$$

2. O decisor deve fixar a turbinagem média diária na USB ($\bar{T}_{USB}$) e o vertimento médio ($\bar{V}_{USB}$).
3. Deve fixar o vertimento médio na ULG ($\bar{V}_{ULG}$).
4. Devido a conveniência operacional da cascata, o decisor deve fixar a turbinagem diária em UAS e nas usinas de UPA (T_{UAS} , T_{USU} , T_{USD} e T_{UST}), ocasionando o não aparecimento dessas UHEs na modelagem matemática.
5. As defluências médias de ULG e UXG são fixadas como a defluência média da cascata.
6. Se a defluência diária for maior que o seu engolimento máximo em todas as UHEs, a vazão excedente deve ser vertida.

Antes da apresentação da formulação matemática, será feito um comentário sobre a restrição de defluência média diária, denominada aqui de Defluência Meta (DM). Esta restrição fixada pode ser representada como a seguir na Equação 5.2

$$\sum_{j=1}^{24} 3600q_i^j = 24 \times 3600Q_i \quad (5.2)$$

onde 3600 é o número de segundos do intervalo de tempo (uma hora), q_i^j é a vazão média turbinada durante o intervalo de tempo j , e Q_i é a vazão média que a usina i deve manter ao longo do dia. Portanto, o lado esquerdo da Equação 5.2 dá o volume total que a usina turbinada ao longo do dia e o lado direito dá volume total que a usina deve defluir ao longo de 24 intervalos de uma hora para atingir a DM.

Adotando o modelo para a geração de potência em uma unidade de geração hidrelétrica dada pela Equação 5.3, ou também na forma da Equação 5.4 que destaca o fator produtividade na Equação 5.5. Então a Equação 5.2 pode ser reescrita como na Equação 5.6:

$$p_i(x_i, q_i) = \eta_i(x_i, q_i)(h_m(x_i) - h_t(q_i) - h_h(q_i))q_i \quad (5.3)$$

ou,

$$p_i(x_i, q_i) = \rho_i(x_i, q_i)q_i \quad (5.4)$$

onde,

$$\rho_i(x_i, q_i) = \eta_i(x_i, q_i)(h_m(x_i) - h_t(q_i) - h_h(q_i)). \quad (5.5)$$

Logo,

$$\sum_{j=1}^{24} \frac{p_i^j}{\rho_i(x_i^j, q_i^j)} = 24Q_i \quad (5.6)$$

A Equação 5.6 expressa a restrição de DM em termos da potência gerada com a produtividade dependente da turbinagem e do volume armazenado. Os níveis dos reservatórios de USB e ULG apresentam variações mínimas em um horizonte diário. Desse modo pode-se considerar que a Equação 5.6 depende apenas da vazão turbinada. Ou seja,

$$\sum_{j=1}^{24} \frac{p_i^j}{\rho_i(x_i^0, q_i^j)} = 24Q_i \quad (5.7)$$

onde x_i^0 é o volume inicial do reservatório i .

Além disso, existe uma relação não linear entre vazão turbinada e potência gerada, de forma que se pode obter a função ρ em função da potência:

$$\sum_{j=1}^{24} \frac{p_i^j}{\rho_i(x_i^0, p_i^j)} = 24Q_i \quad (5.8)$$

5.2 Formulação Matemática

A formulação a ser apresentada é para UHEs que possuem máquinas iguais ou com características distintas, principalmente em termos de curva de eficiência. Para o modelo é preciso dispor dos dados precisos e atualizados de cada UG.

$$\text{Max } \frac{\sum_{j=1}^{24} d^j}{\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{y_{i,k}^j p_{i,k}^j}{\eta_i(p_{i,k}^j)}} \quad (5.9)$$

$$\text{Min } \sum_{j=2}^{24} \sum_{i \in UHE} \sum_{k=1}^{n_i} |y_{i,k}^j - y^j - 1_{i,k}| \quad (5.10)$$

$$\text{s.a. } \sum_{i \in UHE} \sum_{k=1}^{n_i} p_{i,k}^j = d^j - \overline{G} \quad (5.11)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{USB}^j}{\rho_{USB}(x_{USB}^0, p_{USB,k}^j)} = 24Q_{USB} \quad (5.12)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{ULG}^j}{\rho_{ULG}(x_{ULG}^0, p_{ULG,k}^j)} = 24Q_{ULG} \quad (5.13)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{USQ}^j}{\rho_{USQ}(x_{USQ}^0, p_{USQ,k}^j)} = 24Q_{USQ} \quad (5.14)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_{UXG}^j}{\rho_{UXG}(x_{UXG}^0, p_{UXG,k}^j)} = 24Q_{UXG} \quad (5.15)$$

$$p_{i,k}^{j,min} y_{i,k}^j \leq p_{i,k}^j \leq p_{i,k}^{j,max} y_{i,k}^j \quad (5.16)$$

$$y_{i,k}^j \in \{0,1\} \quad (5.17)$$

para $i \in UHE = \{USB, ULG, USQ, UXG\}$, $k = \{1, \dots, n_i\}$ e $j = 1, \dots, 24$.

As funções objetivo 5.9 - 5.10 têm caráter multiobjetivo, as quais buscam maximizar a produtividade e minimizar o número de partidas e paradas. A produtividade é representada individualmente para cada UG e a cada uma delas é associada uma variável booleana que indica se ela está em operação nesse intervalo de tempo. A Equação 5.11 representa o atendimento do mercado¹, uma para cada intervalo de tempo e a Equação 5.12 representa as restrições de DM, uma para cada UHE. A restrição 5.16 representa os limites de geração de cada unidade geradora. E, finalmente, a última restrição (Equação 5.17) define as variáveis booleanas.

O problema 5.9-5.17 é um problema de natureza não linear inteira mista e com não linearidades, tanto na função objetivo como também nas restrições.

O referido problema foi tratado através de técnicas de otimização linear e AG. A motivação da utilização do AG se deu através do trabalho realizado por Colnago (2007) que também desenvolveu

¹ A demanda a ser atendida é a geração prevista da CHESF, descontando as gerações de usinas térmicas, intercâmbios e gerações de outras UHEs (UAS e UPA).

um modelo de despacho ótimo em UG, maximizando a eficiência global de geração das UHEs, utilizando as técnicas da otimização global e local como métodos de resolução. No sentido de se obter um ganho de tempo na resolução do problema e no sentido de mostrar que o AG tornou-se uma ferramenta de otimização poderosa, a sua escolha foi feita. Como já dito, alguns trabalhos mostraram que a utilização dele mostrou-se eficiente para problemas análogos a essa dissertação descritos na Subseção 2.4.2.

5.3 Técnica de resolução

A formulação acima apresentada é resolvida em duas etapas, como segue a Figura 5.2.

A Etapa 1 determina quanto cada UHE deve gerar a cada intervalo de tempo, ou seja, ela oferece uma solução inicial que leva em conta o atendimento do mercado e as defluências médias




Figura 5.2 - Esquema de resolução do problema proposto.

por usina. A partir dessa solução inicial, a Etapa 2 determina o número de unidades em operação e a carga de uma usina específica. Esta última é dividida em duas fases que são resolvidas iterativamente até a convergência. Na Fase 1 a solução inicial é obtida através da resolução de um problema de otimização contínua simplificado. Já na Fase 2, é resolvido um problema não-linear misto, o qual é solucionado por um método matemático/computacional chamado Algoritmo Genético. Esse modelo é considerado para UGs despachadas independentemente, pois, cada UG é tratada de forma individual.

5.3.1 Etapa 1: Cálculo da Geração das UHEs e Alocação da carga nas UHEs

Essa etapa resolve um problema simplificado apresentado a seguir, o qual não decide sobre o número de máquinas em operação.

$$\text{Min} \sum_{j=1}^{24} \sum_{i \in UHE} \frac{p_i^j}{\bar{\rho}_i} \quad (5.18)$$

$$\text{s.a.} \sum_{i \in UHE} p_i^j = d^j - \bar{G} \quad (5.19)$$

$$\sum_{j=1}^{24} \frac{p_i^j}{\bar{\rho}_{USB}} = 24Q_{USB} \quad (5.20)$$

$$\sum_{j=1}^{24} \frac{p_{ULG}^j}{\bar{\rho}_{ULG}} = 24Q_{ULG} \quad (5.21)$$

$$\sum_{j=1}^{24} \frac{p_{USQ}^j}{\bar{\rho}_{USQ}} = 24Q_{USQ} \quad (5.22)$$

$$\sum_{j=1}^{24} \frac{p_{UXG}^j}{\bar{\rho}_{UXG}} = 24Q_{UXG} \quad (5.23)$$

$$p_i^{j,min}(1) \leq p_i^j \leq p_i^{j,max}(n_i^j) \quad (5.24)$$

para $i \in UHE = \{USB, ULG, USQ, UXG\}$ e $j = 1, \dots, 24$.

A formulação dessa etapa tem como função objetivo a minimização da vazão turbinada, Equação 5.18, e as produtividades foram consideradas constantes e iguais aos seus valores mé-

dios. Assim, tanto a função objetivo como as restrições se tornam lineares. Os limites de geração foram alterados, sendo o limite inferior dado pela geração mínima de uma UG em operação e o limite superior dado pela geração máxima de todas as unidades disponíveis em operação.

O problema 5.18 à 5.24 é resolvido através de técnica de programação linear. Sua resolução determina quanto cada UHE da cascata deve gerar de potência ativa a cada intervalo de tempo. Este conjunto de geração por usina é denominado de Curva de Geração.

5.3.2 Etapa 2: Despacho das UG

Devido ao seu caráter misto, o problema nessa etapa é decomposto em duas fases, resolvidos iterativamente até a convergência. Ambas as fases são solucionadas através das técnicas do AG.

5.3.3 Fase 1: Maximizar Eficiência

A formulação do problema de despacho dessa fase, denominada Maximizar Eficiência, é descrita pela função objetivo e restrições abaixo, com tempo j e UHE i fixos.

$$\text{Max } \frac{d^j}{\sum_{k=1}^{n_i} \frac{y_{i,k}^j p_{i,k}^j}{\eta_i(p_{i,k}^j)}} \quad (5.25)$$

$$\text{s.a. } \sum_{k=1}^{n_i} p_{i,k}^j = d^j - \overline{G} \quad (5.26)$$

$$\sum_{k=1}^{n_i} \frac{p_{i,k}^j}{\rho_i(x_i^0, p_{i,k}^j)} = Q_i \quad (5.27)$$

$$p_{i,k}^{j,min} y_{i,k}^j \leq p_{i,k}^j \leq p_{i,k}^{j,max} y_{i,k}^j \quad (5.28)$$

$$y_{i,k}^j \in \{0,1\} \quad (5.29)$$

A formulação possui como objetivo a Equação 5.25, maximizando a eficiência de uma UHE a cada período, ou seja, essa fase é executada 24 vezes. As restrições novamente tratam sobre o aten-

dimento do mercado (Equação 5.26), DM (Equação 5.27), limites de geração das UGs (Equação 5.28) e variáveis booleanas (Equação 5.29).

5.3.4 Algoritmo Fase 1

Representação das variáveis

Na formulação do problema acima apresentada, há dois tipos de variáveis: a geração de uma UHE em cada período p_i^j e uma variável booleana que indica se a UG k foi despachada em um dado horário j ($y_{i,k}^j$). Na implementação do problema, algumas simplificações foram feitas. A variável $y_{i,k}^j$ foi tratada implicitamente restando só a variável p_i^j . O AG da primeira fase é executado para cada um dos j períodos. Para melhor compreensão, cada solução dessa fase, ou indivíduo, é da forma:

$$I = [p_i^j \cdots p_{n_i}^j],$$

onde j é o período de tempo. O vetor I é de tamanho n_i , que representa o número de UGs presentes na UHE.

Um exemplo de um possível indivíduo é mostrado na sequência:

$$I = [120 \ 150 \ 0 \ 114 \ 126 \ 0]$$

Na referência de solução acima, tem-se seis UGs e um período cuja demanda é de 610 MW, fazendo com que a soma dos genes seja igual a 610. No exemplo dado, duas UGs não foram despachadas, as de número 3 e 6 e, nesse caso, os seus genes são iguais a zero.

População inicial

Na população inicial, cria-se um vetor de tamanho n cujas entradas são 0 ou 1 geradas aleatoriamente. Com isso, é determinado quais UGs que não serão despachadas (0) ou que serão despachadas (1) e, portanto, terão geração alocadas a elas. Assim, divide-se igualmente a demanda entre as posições que possuam o gene igual a 1. Se assim for feito e verificar-se que o limite de geração de alguma UG for violada, é gerado novamente um vetor com entradas 0 e 1 até que esses não sejam mais violadas.

As posições que possuem as entradas positivas serão divididas em pares escolhidos aleatoriamente. Para cada par é escolhida a posição que terá o seu valor aumentado e qual terá seu valor diminuindo, também aleatoriamente.

A fim de expressar com maior clareza, seja o exemplo: dada uma demanda d^j e seis UGs, cada uma com geração limitada entre $\underline{p}_{kj}$ e $\bar{p}_{kj}$. Supõe-se que o vetor binário gerado aleatoriamente seja $[1 \ 1 \ 0 \ 1 \ 1 \ 0]$. Em seguida divide-se d^j por 4 e, com isso, o vetor de geração passa a ser $[p_{1j} \ p_{2j} \ 0 \ p_{4j} \ p_{5j} \ 0]$, no qual $p_{kj} = d^j/4$ para $k = 1, 2, 4, 5$. Supondo que $d^j/4$ está dentro dos limites $\underline{p}_{kj}$ e $\bar{p}_{kj}$, segue-se para a próxima etapa.

As posições que possuem valores maiores que zeros serão divididas em pares, no exemplo em dois pares (1 e 2; 4 e 5). Em cada par é escolhido um elemento para ter o seu valor aumentado e outro para ser diminuído. Seja o par 1 e 2 e, a posição 1 escolhida para ser aumentada e a 2, o contrário. No caso, calcula-se a folga que a geração p_{1j} possa ser aumentada de forma a não violar a geração máxima da UG. A folga seria de $\bar{p}_{kj} - p_{1j}$. Por outro lado, calcula-se a folga para a posição 2 considerando a geração mínima. Com isso, a folga seria de $p_{2j} - \underline{p}_{kj}$. Na sequência, calcula-se um valor entre 0 e $\min\{\bar{p}_{kj} - p_{1j}, p_{2j} - \underline{p}_{kj}\}$ de forma aleatória. Tal valor será representado por c_1 e desta forma, o vetor passa a ser $[p_{1j} + c_1 \ (p_{2j} - c_1) \ 0 \ p_{4j} \ p_{5j} \ 0]$. Este procedimento é feito em todos os pares, garantindo que a soma das entradas do vetor não seja alterada, que os limites de geração não sejam violados e que a população inicial contenha indivíduos diversificados.

Seleção

A forma de seleção é a por roleta, explicado na Subseção 3.1.11.

Cruzamento

O cruzamento utilizado nessa fase é o *crossover* aritmético, explicado na Subseção 3.1.11.

Mutação

A mutação por inversão foi a escolhida para a implementação, exposta na Subseção 3.1.11.

Armazenamento de soluções

Uma quantidade das melhores soluções para cada período j é armazenado para a Fase 2. Essas informações armazenadas são os melhores indivíduos, a eficiência da UHE (função objetivo) associada a cada um deles.

5.3.5 Fase 2: Maximizar Eficiência e Minimizar Partidas/Paradas

A formulação do problema de despacho dessa segunda fase, denominada Maximizar Eficiência e Minimizar Partidas/Paradas, é descrita pela função objetivo e restrições abaixo, com UHE i fixa.

$$\text{Max} \sum_{j=1}^{24} \sum_{k=1}^{n_i} \eta_i(p_{i,k}^j) y_{i,k}^j \quad (5.30)$$

$$\text{Min} \sum_{j=2}^{24} \sum_{k=1}^{n_i} |y_{i,k}^j - y^j - 1_{i,k}| \quad (5.31)$$

$$\text{s.a.} \sum_{k=1}^{n_i} p_{i,k}^j = d^j - \bar{G} \quad (5.32)$$

$$\sum_{j=1}^{24} \sum_{k=1}^{n_i} \frac{p_i^j}{\rho(x_i^0, p_{i,k}^j)} = 24Q_i \quad (5.33)$$

$$p_{i,k}^{j,min} y_{i,k}^j \leq p_{i,k}^j \leq p_{i,k}^{j,max} y_{i,k}^j \quad (5.34)$$

$$y_{i,k}^j \in \{0,1\} \quad (5.35)$$

para $i \in UHE = \{USB, ULG, USQ, UXG\}$, $k = 1, \dots, n_i$ e $j = 1, \dots, 24$.

As funções objetivo 5.30 e 5.31 possuem caráter multiobjetivo, as quais buscam maximizar a produtividade e minimizar o número de partidas e paradas. A produtividade é representada individualmente para cada UG associada a uma variável booleana indicando se esta está em operação em um intervalo de tempo. A Equação 5.32 representa o atendimento do mercado, a Equação 5.33 representa a restrição de DM para a UHE escolhida e finalmente a Equação 5.34 representa os limites de geração de cada UG e as variáveis booleanas são definidas na Equação 5.35.

Este problema foi tratado por uma abordagem híbrida, combinando uma metodologia baseada nos AG com SPEA.

5.3.6 Algoritmo Fase 2

Representação das variáveis

Na segunda fase, cada indivíduo possui m genes, os quais se referem a um período j e cada um possui um valor que se refere a uma solução armazenada na Etapa 1. Cada indivíduo é da forma

$$I = [k_1 \ k_2 \ k_3 \ \cdots \ k_m].$$

Sendo que para o período j foram armazenadas K_j soluções, tem-se que $0 \leq k_j \leq K_j$.

População inicial

A população inicial é criada selecionando aleatoriamente cada valor k_j entre 0 e K_j .

Seleção

A forma de seleção é a do método SPEA, explicado na Subseção 4.6.1.

Cruzamento

O cruzamento utilizado nessa etapa é o de um ponto, descrito na Subseção 3.1.11.

Mutação

Foi utilizada a mutação inteira para a Etapa 2. A mesma é realizada de acordo com uma probabilidade (taxa de mutação) e consiste em trocar um gene j por um número entre 0 e K_j aleatoriamente.

6 CENÁRIOS DE ESTUDO

6.1 Ajustes das curvas de eficiência

O desempenho de geração em uma usina tem como principal fator a eficiência das UGs. Ela é descrita por uma superfície tridimensional denominada Curva Colina. Tal superfície, no entanto, é originada através de um conjunto de pontos interligados que pode ser observado na Figura 6.1.




Figura 6.1 - Pontos de eficiência para uma altura de queda fixa

É importante que nesta dissertação, para maior clareza da técnica de resolução, obter-se uma função(ões) contínua(s) que represente(m) a curva. Em um estudo feito por Esteves et al. (2006), foi proposto uma aproximação dos pontos de uma curva colina através de um polinômio de quarto grau em função das variáveis de altura de queda e potência, dando realce a um melhor ajuste ao ponto máximo de eficiência da curva colina. Esses ajustes foram feitos em espaços bidimensionais que podem ser realizados fixando a altura de queda em diversos valores e para cada um, tem-se a eficiência em função da potência. O nível de erros com esse tipo de aproximação é menor que o ajuste tridimensional. Um exemplo de pontos de eficiência para uma altura de queda é mostrado na Figura 6.1. Com isso, nesta dissertação foi proposto utilizar aproximações bidimensionais por

polinômios de quarto grau utilizando o Método dos Quadrados Mínimos .

6.1.1 Método dos Quadrados Mínimos

O Método dos Quadrados Mínimos (MQM) obtém valores otimizados dos parâmetros de uma reta ou curva, ou seja, ele ajusta os coeficientes de um polinômio com a finalidade de minimizar a soma dos quadrados dos erros na aproximação. Dados n pontos (x_i, y_i) em um plano, o objetivo é encontrar uma função polinomial de grau k , $f(x) = a_k x^k + a_{k-1} x^{k-1} + \dots + a_1 x + a_0$, na qual $k \geq 1$, que melhor se aproxime dos pontos dados.

Se $n = k$ o polinômio interpolará os n pontos e por isso, $n > k$. Na Figura 6.2 pode-se notar os pontos (x_i, y_i) com um polinômio ajustado a eles por MQM. É indicado um ponto e sua aproximação $(x_i, \hat{y}_i)$ onde $f(x_i) = \hat{y}_i$. O erro quadrático na aproximação desse ponto é $(y_i - f(x_i))^2$. Como já dito, o MQM trata de minimizar a soma de todos os erros quadráticos, ou seja, minimizar

$$E = \sum_{i=1}^N (y_i - f(x_i))^2 = \sum_{i=1}^N (y_i - a_k x_i^k - a_{k-1} x_i^{k-1} - \dots - a_1 x_i - a_0)^2. \quad (6.1)$$




Figura 6.2 - Aproximação por MQM: Pontos y_i e suas aproximações $\hat{y}_i$

Os erros ao quadrado são utilizados por que eles não se cancelam, fato que aconteceria com os erros $y_i - f(x_i)$. Erros negativos poderiam ser cancelados com erros positivos implicando uma pequena alteração na soma total dos mesmos mas com erros altos em módulo. E também, porque erros altos são majorados quando levados ao quadrado, fazendo com que a curva busque ajustar-se o melhor possível de todos os pontos.

A solução ótima do MQM ou a solução que minimiza E na Equação 6.1, é dada pelo vetor

$$a = \begin{bmatrix} a_k \\ a_{k-1} \\ \vdots \\ a_0 \end{bmatrix} \quad (6.2)$$

que resolve o sistema linear de tamanho $(k+1) \times (k+1)$:

$$A^T A a = A^T Y, \quad (6.3)$$

sendo

$$A = \begin{bmatrix} x_1^k & x_1^{k-1} & \cdots & 1 \\ x_2^k & x_2^{k-1} & \cdots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ x_N^k & x_N^{k-1} & \cdots & 1 \end{bmatrix} \quad (6.4)$$

e

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}. \quad (6.5)$$

6.1.2 Método dos Quadrados Mínimos ponderados

O Método dos Quadrados Mínimos ponderados é uma modificação do MQM, pois nele são alocados pesos aos n pontos (x_i, y_i) . Os pontos que possuírem pesos maiores indicaram que o

polinômio a ser interpolado se aproximará mais dele. Esses terão uma maior influência na aproximação da curva do que os outros pontos com pesos menores.

Considere o peso p_i dado ao ponto (x_i, y_i) . Assim, o MQM ponderados tem como objetivo minimizar o erro quadrático ponderado

$$Ep = \sum_{i=1}^N p_i (y_i - f(x_i))^2,$$

e esse, por sua vez, é minimizado por a , solução do sistema $(k+1) \times (k+1)$

$$PA^T Aa = PA^T Y,$$

sendo

$$P = \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_N \end{bmatrix}. \quad (6.6)$$

A Figura 6.3 mostra dois ajustes realizados utilizando MQM e MQM ponderados a um conjunto de dados. No ajuste por MQM ponderados, foi adotado um peso maior ao ponto cuja potência é próxima a 110 MW e eficiência de 96 % e aos outros pontos foram alocados pesos iguais. A curva obtida por MQM possui o menor erro quadrático total que o MQM ponderados. Os dois polinômios na Figura 6.3 possuem comportamentos distintos, devido ao ajuste por MQM ponderado aproximou-se mais do ponto com maior peso. O tipo de ajuste a se escolher depende da aplicação e dos dados do problema.




Figura 6.3 - Aproximações de polinômios de grau 4 por MQM e MQM ponderados

6.2 Estudo de caso

Essa seção apresenta um estudo de caso da aplicação do modelo proposto, considerando a programação realizada no dia 10 de setembro de 2007.

6.2.1 Dados

O caso de estudo considerou um horizonte diário com discretização de uma hora com todas as UHEs da cascata. A Tabela 6.1 que mostra a curva de carga a ser atendida pelas UHEs da cascata e a Tabela 6.2, mostra o estado inicial dos reservatórios e as afluências (média diária) esperada para este dia.

Tabela 6.1 - Curva de carga da cascata

Fonte: Dados fornecidos pela CHESF do dia 10 de setembro de 2007.

Hora	Carga (MW)	Hora	Carga (MW)
00h00	6421	12h00	7215
01h00	6241	13h00	7424
02h00	6159	14h00	7657
03h00	6110	15h00	7711
04h00	6129	16h00	7497
05h00	6018	17h00	7435
06h00	6018	18h00	8143
07h00	6613	19h00	7839
08h00	6996	20h00	7524
09h00	7350	21h00	7671
10h00	7525	22h00	7389
11h00	7436	23h00	6877

Tabela 6.2 - Dados de Usinas

Fonte: Dados fornecidos pela CHESF.

UHE	Reservatório (hm ³)
ULG	10539
UAS/USQ	1232
UXG	3779
UHE	Afluência média (m ³ /s)
ULG	2630
USB	900

A Tabela 6.3 apresenta os valores fixados para a defluência diária de USB e as defluências (turbinagem e vertimento) de UAS e UPA.

Tabela 6.3 - Condições de Contorno

Fonte: Dados fixados pelo decisor na implementação computacional.

UHE	Turbinagem (m ³ /s)
USB (média)	2744
UAS (fixa)	965
USU (fixa)	0
USD (fixa)	0
UST (fixa)	965
UHE	Vertimento (m ³ /s)
USB	0
ULG	0

Também foi fixado o número de máquinas em operação das usinas USB, USQ e UXG, conforme

Tabela 6.4.

Tabela 6.4 - Máquinas despachadas

USB	ULG	UXG
5	6	6

6.3 Estrutura de dados

Para a implementação do modelo matemático apresentado no Capítulo 5, foram escolhidas duas ferramentas computacionais: *Microsoft Excel® 2000* e *software Matlab® 7.0*. Primeiramente o *Excel* recebe os dados de entrada que são transferidos para o *Matlab*, através de Macros de programação. O *Matlab* executa o modelo de otimização e gera os resultados que serão, novamente, transferidos para as planilhas do *Excel*, conforme Figura 6.4.




Figura 6.4 - Esquema de resolução do modelo matemático

Os resultados serão divididos em quatro planilhas apresentadas a seguir.

6.3.1 Planilha : Estudo de caso

A planilha em destaque tem como objetivo a inserção de dados para a realização do estudo de caso das UHEs da mesma cascata. A sua interface é de fácil manipulação, como mostrado na Figura 6.5.

DADOS

Reservatório (Hm³)

ULG

UAS/USQ

UXG

Afluência média (m³/s)

ULG

Produtividade média (MW/m³/s)

USB

ULG

USQ

UXG

UAS

USU

ULD

UST

Carga (MW)

1	00h00	6640
2	01h00	6390
3	02h00	6268
4	03h00	6218
5	04h00	6275
6	05h00	6103
7	06h00	6272
8	07h00	6716
9	08h00	7370
10	09h00	7717
11	10h00	7850
12	11h00	7748
13	12h00	7504
14	13h00	7739
15	14h00	7989
16	15h00	7997
17	16h00	7793
18	17h00	7779
19	18h00	8195
20	19h00	8166
21	20h00	7832
22	21h00	7966
23	22h00	7560
24	23h00	6988

DECISÕES

Turbinagem (m³/s)

USB (média)

UAS (fixa)

USU (fixa)

USD (fixa)

UST (fixa)

Vertimento (m³/s)

USB

ULG

Quantidade de UG

USB

ULG

UXG

Executar

Figura 6.5 - Interface da planilha de estudo de caso

A planilha acima está dividida em dois campos: Dados e Decisões. No campo de Dados são inseridas as informações de Reservatório (hm^3), Afluência média (m^3/s), Produtividade média [$\text{MW}/(\text{m}^3/\text{s})$] e Carga (MW). Se os dados inseridos não forem numéricos, automaticamente, aparecerá uma mensagem de erro após clicar o botão de executar, indicando onde o dado deve ser numérico.

No campo de Decisões, são inseridas as informações de Turbinagem (m^3/s), Vertimento (m^3/s) e Quantidade de UG. Para este último campo, o número de UHE deve estar entre 1 e 6, caso contrário, aparecerá uma mensagem de erro.

Após inseridas todas as informações de estudo de caso, pode-se realizar a otimização. O botão para a

inicialização encontra-se no canto direito inferior da planilha, denominado executar. Ao acionar o botão, a tela, Figura 6.6, é mostrada.

DADOS

Reservatório (Hm3)

ULG: 10000

UAS/USQ: 1219,8

UXG: 3765,2

Afluência média (m3/s)

ULG: 2500

Produtividade média (MW/m3/s)

USB: 0,2450

ULG: 0,4800

USQ: 1,0700

UXG: 1,1000

UAS: 0,1675

USU: 0,7324

ULD: 0,7240

UST: 0,7880

Carga (MW)

1	00h00	6640
2	01h00	6390
3	02h00	6268
4	03h00	6218
5	04h00	6275
6	05h00	6103
7	06h00	6272
8	07h00	6716
9	08h00	7370
10	09h00	7717
11	10h00	7850
12	11h00	7748
15	14h00	7989
16	15h00	7997
17	16h00	7793
18	17h00	7779
19	18h00	8195
20	19h00	8166
21	20h00	7832
22	21h00	7966
23	22h00	7560
24	23h00	6988

DECISÕES

Turbinagem (m3/s)

USB (média): 2530

UAS (fixa): 1209

USU (fixa): 0

USD (fixa): 0

UST (fixa): 1209

Vertimento (m3/s)

USB: 250

Quantidade de UG

USB: 6

ULG: 6

UXG: 6

Em execução. Aguarde....

Executar

Figura 6.6 - Mensagem para aguardar a execução

A função do botão é acionar a macro de programação na qual esta executa o modelo proposto no *Matlab*. A finalização do método aloca os resultados em quatro planilhas seguintes:

1. Planilha UHE

Nesta planilha será mostrado o gráfico de uma UHE em específico. Nela será apresentado o resultado da geração e turbinagem a cada período. As gerações máximas e mínimas também estarão representadas.

2. Planilha Cascata

Nesta planilha é mostrado o gráfico da geração total da cascata e das usinas USB, ULG, USQ e UXG e os níveis de seus reservatórios.

3. Planilha Balanço Hidráulico

Na planilha de Balanço Hidráulico está a representação do conjunto de usinas da mesma cascata

com suas respectivas médias diárias de defluências.

4. Planilha Tabelas

Nessa planilha são apresentadas todas as informações do programa otimizado divididas em Tabelas. Nelas estão os parâmetros fixos, que são os dados fornecidos na planilha Estudo de Caso pelo decisor, os resultados para Turbinagem (m^3/s), Geração (MW) , Quantidade de UG e Reservatório (hm^3) de cada usina em um dia de operação, dividido em intervalos de uma hora cada.

6.4 Estudo de caso 1: Sobradinho

A UHE de Sobradinho possui seis UGs e na Figura 6.7 pode ser visto as curvas modificadas ao longo dos anos. As UGs foram construídas com as mesmas características na década de 1970 e nos anos 2000 apresentaram novas medições, constatando-se as particularidades das UGs. Os dados de eficiência dessas foram calculados pela empresa LENINGRADSKY METALLICHESKY ZAVOD utilizando o método de medição de vazão *Witner Kennedy* (ARM, 2003). Esses dados (Tabela 6.5) se referem à altura de queda de 24,8 m para cinco unidades e essas informações estão tabuladas em relação as suas eficiências e potências. A outra unidade se refere à altura de queda de 20,4 m.




Figura 6.7 - Curvas de eficiência das UGs da UHE Sobradinho, medidas após quase 30 anos de instalação

Potência (MW)	Eficiência (%)				
	UG 1	UG 2	UG 3	UG 5	UG 6
50	86,52		87,25	87,40	85,30
60	88,00	87,50	88,25	88,40	86,75
70	89,35	89,00	89,20	89,30	88,00
80	90,50	90,40	90,34	90,50	89,15
90	91,18	91,20	91,40	91,50	90,10
100	91,50	91,65	91,90	91,96	90,90
110	91,85	91,90	92,00	92,00	91,60
120	92,00	92,00	91,98	92,00	92,00
130		91,90	91,81	91,95	91,90
140		91,70	91,48	91,80	91,50

As eficiências máximas para esses conjuntos de dados são de 92%. Esse valor provavelmente ocorreu, porque, as eficiências relativas medidas a partir de um ponto de eficiência máximo foi fixado em 92% por corresponder ao ponto de projeto da unidade, verificando a diferença entre eficiências correspondentes à potências diferentes.

Nas análises descritas, na sequência, foram utilizados dois tipos de ajustes:

- Ajuste por MQM;
- Ajuste por MQM ponderados.

sendo adotados dois critérios principais para seleção do melhor método:

- Menor erro na aproximação da curva aos pontos (erro médio quadrático e erro médio absoluto);
- Menor ajuste ao ponto de máxima eficiência.

As Figuras 6.8 - 6.12 mostram o resultado dos ajustes feitos nas curvas de eficiência das UGs de Sobradinho.




Figura 6.8 - Curva de eficiência da UG 1 da UHE Sobradinho




Figura 6.9 - Curva de eficiência da UG 2 da UHE Sobradinho




Figura 6.10 - Curva de eficiência da UG 3 da UHE Sobradinho




Figura 6.11 - Curva de eficiência da UG 5 da UHE Sobradinho




Figura 6.12 - Curva de eficiência da UG 6 da UHE Sobradinho

As medições feitas da UG 4 foram colhidas de uma altura de queda de 20,4 m. Assim sendo, os dados da mesma foram transpostos para a altura de queda de 24,8 m. Para essa finalidade, utilizou-se o procedimento indicado na norma NB-228 (1974). A transposição, nessa norma, tem como objetivo estimar os dados para uma altura de queda H_n , que possui as condições da garantia de rendimento da turbina a partir dos dados referentes a H , condições do ensaio, usando as fórmulas

$$\frac{P_n}{P_t} = C^2 \left(\frac{H'}{H} \right)^{\frac{3}{2}} \quad (6.7)$$

e

$$\frac{Q'}{Q} = C^2 \left(\frac{H'}{H} \right)^{\frac{1}{2}}, \quad (6.8)$$

onde H' , P_n , e Q' são, respectivamente, a altura de queda, potência, e vazão turbinada em um sistema hidromecânico; e H , P_t , e Q são as mesmas grandezas mencionadas anteriormente, mas referentes a outro modelo. Em (NB-228, 1974), apresenta-se uma fórmula para o cálculo da eficiência η_t quando fixado um trio P_t , Q e H . A fórmula é a seguinte:

$$\eta_t = \frac{P_t}{K \gamma Q H}, \quad (6.9)$$

onde $K = \frac{1000}{102}$ e γ é uma constante que depende da altitude, latitude e peso específico da água.

Considerando que trata-se do mesmo modelo hidromecânico, tem-se que o fator de escala C da fórmula 6.7 é um. Sendo P_t a potência referente a H , a atualização da potência para as condições H_n é retirada da fórmula 6.7 e fica da seguinte forma

$$P_n = P_t \left(\frac{H_n}{H} \right)^{\frac{3}{2}}. \quad (6.10)$$

Extrapolados os valores para serem referentes a H_n , a eficiência pode ser calculada pela fórmula 6.9. Como os dados das 5 UGs (1,2,3,5 e 6) referentes a $H_n = 24,8 \text{ m}$ estão com um ponto máximo de eficiência de 92%, e a eficiência máxima dos dados da UG 4 está em um valor abaixo disso. Os dados dessa UG, após extrapolados para $H_n = 24,8 \text{ m}$, foram transpostos de forma que o ponto de máxima eficiência estivesse em 92%. A Figura 6.13 mostra os dados originais ($H_t = 20,4 \text{ m}$) e os transpostos para $H_n = 24,8 \text{ m}$. A Tabela 6.6 possui os dados da UG 4 já transpostos que foram utilizados nos ajustes e a Figura 6.14 mostra graficamente o resultado desses ajustes.

Tabela 6.6 - Dados de eficiência da UG 4			
$H = 20,4\text{m}$		$H = 24,8\text{m}$	
Potência (MW)	Eficiência (%)	Potência (MW)	Eficiência (%)
50,00	84,60	67,02	85,80
60,00	87,00	80,42	88,20
70,00	88,87	93,83	90,07
80,00	89,83	107,23	91,03
90,00	90,71	120,64	91,91
100,00	90,80	134,04	92,00
110,00	88,63	147,44	89,83




Figura 6.13 - Transposição dos dados de eficiência da UG 4




Figura 6.14 - Ajuste polinomial feito para a UG4 da UHE Sobradinho

Doravante, os coeficientes a_i ($i = 0, \dots, 4$) dos polinômios da UHE de Sobradinho estão na Tabela 6.7, sendo o polinômio da forma:

$$\eta(P) = a_4 P^4 + a_3 P^3 + a_2 P^2 + a_1 P + a_0 \quad (6.11)$$

onde $\eta(P)$ é a eficiência referente à potência P .

Tabela 6.7 - Coeficientes dos ajustes polinomiais da UHE de Sobradinho

UG	a_4	a_3	a_2	a_1	a_0
1	-2.99e-008	1.48e-005	-3.70e-003	4.55e-001	7.13e+001
2	-1.00e-007	4.93e-005	-9.92e-003	9.43e-001	5.71e+001
3	6.47e-008	-1.92e-005	5.51e-004	2.32e-001	7.58e+001
4	-3.13e-007	1.08e-004	-1.46e-002	1.03e+000	5.61e+001
5	4.02e-008	-1.722e-005	1.65e-003	6.72e-002	8.17e+001
6	2.04e-007	-9.03e-005	1.30e-002	-6.42e-001	9.49e+001

6.5 Estudo de caso 2: Paulo Afonso IV

A UHE Paulo Afonso IV faz parte do complexo Paulo Afonso e sua construção iniciou-se em 1973. Ela possui 6 UGs, com potência mínima de 200 e máxima de 400 MW. A geração da primeira UG começou em 1979 e, a partir de 1983, a UHE estava gerando com as 6 unidades instaladas. Ela possui uma capacidade nominal de 2.462.400 kW, sendo 410.400 kW para cada unidade.

A curva de eficiência de USQ, mostrada a seguir (Figura 6.15) foi construída através da coleta de dados disponíveis no *software* HYDROLAB. Este *software* foi desenvolvido pelo grupo de pesquisa denominado COSE - Laboratório de Coordenação da Operação de Sistema Eletroenergéticos. O COSE pertence ao Departamento de Sistemas da Faculdade de Engenharia Elétrica e de Computação - FEEC, na UNICAMP.




Figura 6.15 - Curva de eficiência de Paulo Afonso 4 de acordo com os dados coletados.

O HYDROLAB é um sistema de apoio à decisão para o planejamento e a programação da operação do

Sistema Interligado Nacional - SIN, composto por um banco de dados cadastrais com todas as informações do sistema energético brasileiro e de pós operação das UHEs (HYDRODATA), uma base de dados das usinas termoeletricas (TERMODATA), um modelo de otimização a UHE individualizadas (HYDROMAX), modelos de programação dinâmica determinística (PDD), estocástica independente (PDEI), e estocástica Markoviana (PDEM), um modelo de simulação a UHE individualizadas em base mensal (HYDROSIM LP), um modelo de simulação a UHE individualizadas em base horária (HYDROSIM CP), um modelo de previsão de vazões em base mensal e semanal (HYDROPREV), um modelo de despacho de máquinas e de geração (HYDRODESP) e um modelo de fluxo de potência ótimo em corrente contínua (FPOcc).

Os dados coletados encontram-se no HYDRODATA, mais especificamente na aba curva colina que é uma extensão da aba casa de máquinas.

Para a simulação foi preciso encontrar as curvas individualizadas e os coeficientes de cada UG de USQ e, para isto, foram feitas estimativas destas curvas com as de Sobradinho, medidas há 31 anos atrás e recentemente. Esta comparação foi feita devido ao fato de que ambas possuem, aproximadamente, a mesma idade de funcionamento e o mesmo número de UG.

Para a obtenção dos coeficientes de Paulo Afonso IV, primeiramente, foram traçadas as curvas de eficiência de cada UG de Paulo Afonso IV baseadas nas de Sobradinho, estimando como seriam essas curvas depois de alguns anos, gerando as Figuras 6.16- 6.21. Em seguida, sofreram um ajuste por MQM com menor erro na aproximação da curva aos pontos.




Figura 6.16 - Curva de eficiência estimada com ajuste polinomial feito para a UG 1 da UHE Paulo Afonso IV




Figura 6.17 - Curva de eficiência estimada com ajuste polinomial feito para a UG 2 da UHE Paulo Afonso IV




Figura 6.18 - Curva de eficiência estimada com ajuste polinomial feito para a UG 3 da UHE Paulo Afonso IV




Figura 6.19 - Curva de eficiência estimada com ajuste polinomial feito para a UG 4 da UHE Paulo Afonso IV




Figura 6.20 - Curva de eficiência estimada com ajuste polinomial feito para a UG 5 da UHE Paulo Afonso IV




Figura 6.21 - Curva de eficiência estimada com ajuste polinomial feito para a UG 6 da UHE Paulo Afonso IV

Para a implementação, foram selecionadas seis curvas já que Paulo Afonso IV possui 6 UGs. A escolha destas deu-se através de um sorteio aleatório feito entre as curvas estimadas com os ajustes, apresentadas acima. A saber, as Figuras 6.22 - 6.27 mostram três curvas: duas escolhidas aleatoriamente e uma outra gerada entre essas.




Figura 6.22 - Curva gerada entre as curvas das UGs 3 e 2




Figura 6.23 - Curva gerada entre as curvas das UGs 6 e 5




Figura 6.24 - Curva gerada entre as curvas das UGs 6 e 2




Figura 6.25 - Curva gerada entre as curvas das UGs 1 e 3




Figura 6.26 - Curva gerada entre as curvas das UGs 2 e 1




Figura 6.27 - Curva gerada entre as curvas das UGs 4 e 3

A Figura 6.28 apresenta essas curvas formadas e a Tabela 6.8 mostra os seus coeficientes utilizados no estudo de caso.




Figura 6.28 - Curvas de eficiência de PA IV supostamente medidas depois de alguns anos de funcionamento.

Tabela 6.8 - Coeficientes das UGs da UHE de Paulo Afonso IV

UG	a_4	a_3	a_2	a_1	a_0
1	2.18e-008	-2.78e-005	1.26e-002	-2.35e+000	2.38e+002
2	2.83e-008	-3.731e-005	1.76e-002	-3.48e+000	3.30e+002
3	1.56e-008	-2.08e-005	9.68e-003	-1.81e+000	1.99e+002
4	1.29e-008	-1.70e-005	7.73e-003	-1.40e+000	1.71e+002
5	4.22e-009	-6.04e-006	2.67e-003	-3.60e-001	9.07e+001
6	-7.34e-009	7.68e-006	-3.473e-003	8.55e-001	-1.65e+000

7 RESULTADOS

Os resultados foram obtidos através do emprego do modelo computacional da programação de operação diária das UHEs do médio São Francisco. Das oito usinas pertencentes à cascata, foram simuladas quatro e as UHEs específicas escolhidas para o estudo de caso foram0 Sobradinho e Paulo Afonso IV. O tempo total de execução do modelo foi 2564 segundos. A Etapa 1 do modelo originou um gráfico que apresenta os resultados em termos de geração para cada uma das UHEs da cascata, como mostrado na Figura 7.1.




Figura 7.1 - Geração total da cascata e das UHEs

Basicamente, todas as UHEs acompanharam a curva de carga e variaram de acordo com ela. Uma vantagem apresentada seria de que estas estão suavizadas devido a abordagem não-linear adotada e estão dentro dos limites operacionais. As Figuras 7.2 - 7.4 mostram os comportamentos dos níveis de reservatórios. Pode-se notar que esses níveis, em todas as UHEs, apresentaram pequenas variações, revelando que essa programação de operação diária é adequada do ponto de vista da operação hidráulica do sistema. A representação adotada pelo modelo é mais simplificada, sendo este outro aspecto importante do resultado, pois ele assegura a coordenação hidráulica da cascata.




Figura 7.2 - Reservatório da UHE Paulo Afonso IV




Figura 7.3 - Reservatório da UHE Luiz Gonzaga




Figura 7.4 - Reservatório da UHE Xingó

Como já dito, na implementação as figuras apresentadas acima são visualizadas na Planilha Cascata. No estudo de caso da UHE USB, a Tabela 7.1 mostra os resultados obtidos na Fase 1 da Etapa 2 para uma demanda de 519,6 MW. Os dados armazenados na tabela acima são informações referentes às combinações das UGs, a eficiência ótima referente à combinação e o vetor de geração do indivíduo. A primeira coluna indica uma combinação de uma solução, como por exemplo o número 55. A representação do número na base binária é 110111, indicando quais UGs estão ativas. No caso são as de número 1, 2, 4, 5 e 6, alocando a geração entre elas. Para cada demanda, essas informações são armazenadas para a Fase 2 do algoritmo.

Tabela 7.1 - Resultados da otimização da Fase 1 do algoritmo para USB - demanda 519,6 MW

Combinação	Eficiência (%)	Geração (MW)					
		UG 1	UG 2	UG 3	UG 4	UG 5	UG 6
55	87,8	114,4	107,2	0	72,8	90,2	135
53	82	139,7	131,9	0	127,9	0	120,1
39	82,2	124,4	0	0	123,6	135,4	136,2
31	86,8	0	80,7	109,6	127,1	95,6	106,6
57	81,6	137,2	122,6	139,5	0	0	120,3
45	81,9	136,8	0	123	128	0	131,7
54	82,4	139,5	132,6	0	127,2	120,3	0
46	82,3	119,9	0	139,9	123,8	136	0
27	81,7	0	129,4	124,1	0	135,7	130,4
15	82,5	0	0	139,8	120	126,6	133,2
43	81,4	124,8	0	128	0	135	131,8
62	87,7	138,5	123,1	84,7	71,7	101,6	0
23	82,3	0	127,8	0	129,9	129,9	132
51	81,7	126,7	122,8	0	0	137	133,1
29	82,1	0	121	123,2	138,8	0	136,6

No caso de Paulo Afonso IV, a Tabela 7.2 mostra os resultados obtidos na Fase 1 da Etapa 2 para uma demanda de 1059,27 MW. Igualmente a de USB, a primeira coluna indica uma combinação de uma solução com sua eficiência ótima e vetor de geração, como por exemplo do número 42. A representação desse número na base binária é 101010, indicando quais UGs estão ativas. No caso são as de número 1, 3, e 5, alocando a geração entre elas.

Tabela 7.2 - Resultados da otimização da Fase 1 do algoritmo para USQ - demanda 1059,3 MW

Combinação	Eficiência (%)	Geração (MW)					
		UG 1	UG 2	UG 3	UG 4	UG 5	UG 6
42	90,5	301,1	0,0	408,2	0,0	350,0	0,0
43	88,2	285,3	0,0	215,0	0,0	314,7	244,4
25	90,7	0,0	364,8	391,1	0,0	0,0	303,4
29	89,0	0,0	179,6	365,8	163,8	0,0	350,1
27	86,9	0,0	361,4	282,0	0,0	247,6	168,3
15	88,1	0,0	0,0	155,9	373,7	303,9	225,8
7	90,8	0,0	0,0	0,0	340,0	324,1	395,2
58	88,7	317,8	186,4	211,9	0,0	343,2	0,0
62	84,5	185,5	241,8	251,9	181,9	198,2	0,0
51	87,1	356,6	281,7	0,0	0,0	247,9	173,1
61	85,6	201,2	290,1	178,5	144,3	0,0	245,2
60	88,5	284,5	341,6	245,1	188,0	0,0	0,0
59	82,9	190,3	225,0	319,1	0,0	198,7	126,2
26	89,0	0,0	368,7	426,4	0,0	264,2	0,0
49	91,6	345,9	367,3	0,0	0,0	0	346,1
45	88,5	225,3	0,0	285,7	243,9	0	304,4
37	89,0	416,7	0,0	0,0	253,4	0	389,2
55	83,8	219,6	207,2	0,0	208,8	210,4	213,3
22	91,7	0,0	342,1	0,0	366,7	350,5	0,0
47	85,1	194,1	0,0	197,7	154,6	269,1	243,8
11	91,6	0,0	0,0	334,5	0,0	371,9	352,9

A Fase 2 fornece um conjunto de soluções não dominadas. No caso de Sobradinho, a Figura 7.5 mostra as 5 soluções juntamente com suas funções objetivos. Essas são as melhores soluções obtidas entre todas as geradas, não existindo uma relação de melhor ou pior entre elas. Analisando a Figura 7.5, tem-se a solução com menor eficiência de 84,19% e também com o menor número de partidas e paradas, oito apenas, representada pelo ponto mais a esquerda. A Tabela 7.3 expõe o despacho dessa solução.




Figura 7.5 - Soluções não dominadas para a UHE de Sobradinho

Tabela 7.3 - Solução encontrada com menor número de partidas e paradas UHE Sobradinho

Horas	1	2	3	4	5	6
1	1	1	1	1	1	1
2	1	1	1	1	1	1
3	1	1	1	0	1	0
4	1	1	1	0	1	0
5	1	1	1	0	1	0
6	1	0	1	1	1	0
7	1	0	1	1	1	0
8	1	0	1	0	1	1
9	1	0	1	1	1	0
10	1	0	1	1	1	1
11	1	1	1	1	1	1
12	1	1	1	1	1	1
13	1	1	1	1	1	1
14	1	1	1	1	1	0
15	1	1	1	1	1	0
16	1	1	1	1	1	1
17	1	1	1	1	1	1
18	1	1	1	1	1	1
19	1	1	1	1	1	1
20	1	1	1	1	1	1
21	1	1	1	1	1	1
22	1	1	1	1	1	1
23	1	1	1	1	1	1
24	1	1	1	1	1	1

A UG que possui uma maior eficiência, 85,12% , possui também o maior número de partidas e paradas, 27. A Tabela 7.4 mostra essa solução, que é representada pelo ponto mais à direita da Figura 7.5.

Tabela 7.4 - Solução encontrada com maior número de partidas e paradas UHE Sobradinho

Horas	1	2	3	4	5	6
1	0	1	1	0	0	1
2	1	1	0	1	1	1
3	1	1	1	1	1	1
4	1	1	1	0	1	0
5	0	1	1	1	1	1
6	1	1	0	1	1	0
7	1	1	0	1	1	0
8	0	1	0	1	1	1
9	1	1	1	0	1	1
10	1	1	1	1	1	1
11	1	1	1	0	1	1
12	1	1	1	1	1	1
13	1	0	1	1	1	1
14	0	1	1	1	1	1
15	1	1	1	1	1	1
16	1	1	1	1	1	1
17	1	0	1	1	1	
18	1	1	1	1	1	1
19	1	1	1	1	1	1
20	1	1	1	1	1	1
21	1	1	1	1	1	1
22	1	1	1	1	1	1
23	1	1	1	1	1	0
24	1	1	1	1	1	0

Já no caso de Paulo Afonso IV, a Figura 7.6 mostra as 7 soluções juntamente os valores das funções objetivos. Analisando essa tem-se a solução com menor eficiência de 90,41% e também com o menor número de partidas e paradas, nove apenas, representada pelo ponto mais a esquerda. A Tabela 7.5 expõe o despacho das UGs.




Figura 7.6 - Soluções não dominadas para a UHE de Paulo Afonso IV

Tabela 7.5 - Solução encontrada com menor número de partidas e paradas UHE Paulo Afonso IV

Horas	1	2	3	4	5	6
1	0	1	1	1	1	0
2	0	1	1	1	1	0
3	0	1	1	1	1	0
4	0	1	1	1	1	0
5	0	1	1	1	1	0
6	0	1	1	0	1	0
7	0	1	1	0	1	0
8	0	1	1	0	1	1
9	1	1	1	0	1	1
10	1	0	1	0	1	1
11	1	0	1	1	1	1
12	1	0	1	1	1	1
13	1	1	1	1	1	1
14	1	1	1	1	1	1
15	1	1	1	1	1	0
16	1	1	1	1	1	0
17	1	1	1	1	1	0
18	1	1	1	1	1	1
19	1	1	0	1	1	1
20	1	1	0	1	1	1
21	1	1	0	1	1	1
22	1	1	0	1	1	1
23	1	1	0	1	1	1
24	1	1	0	1	1	1

A UG que possui uma maior eficiência, 90,76% , possui também o maior número de partidas e paradas, 30. A Tabela 7.6 mostra essa solução, que é representada pelo ponto mais à direita da Figura 7.6.

Tabela 7.6 - Solução encontrada com maior número de partidas e paradas UHE Paulo Afonso IV

Horas	1	2	3	4	5	6
1	0	1	1	1	1	0
2	0	1	1	1	1	0
3	0	1	1	1	1	0
4	1	1	1	0	0	0
5	1	1	0	0	1	0
6	0	1	1	0	1	0
7	0	1	1	0	1	0
8	0	1	1	0	1	1
9	1	0	0	1	1	1
10	1	0	1	0	1	1
11	1	1	1	0	1	1
12	1	0	1	0	1	1
13	1	1	1	1	1	1
14	1	1	1	1	1	1
15	1	1	1	1	1	0
16	1	1	1	1	1	0
17	1	1	1	1	1	0
18	1	1	0	1	1	1
19	1	1	0	1	1	1
20	1	1	1	1	0	1
21	1	1	0	1	1	1
22	0	1	1	1	1	1
23	1	1	0	1	1	1
24	1	1	0	1	1	0

As soluções (Tabela 7.3, Tabela 7.4, Tabela 7.5 e Tabela 7.6) apresentadas possuem 24 linhas referentes a um período de tempo de uma hora. Na primeira coluna tem-se as seis UGs e nas demais, números na base binária que demostram se a UG está ativa no determinado período de tempo. A escolha da melhor solução irá depender da prioridade do problema.

Em termos de eficiência, a solução com 90,76% é melhor, mas se a diminuição do número de partidas e paradas for prioridade, escolhe-se a solução com 90,41%, no caso de Paulo Afonso IV. Na de Sobradinho, a solução com 85,12% é melhor, mas se o número de partidas e paradas for prioridade, a outra solução com eficiência de 84,19% é melhor.

As Figuras 7.8 e 7.7 mostram o resultado em termos da turbinagem e geração para a UHE Sobradinho e Paulo Afonso IV. Nesses gráficos são indicados os limites de geração máxima e mínima, que estão em função do número de máquinas em operação, no respectivo intervalo de tempo.




Figura 7.7 - Geração e Turbinagem para USB




Figura 7.8 - Geração e Turbinagem para USQ

O balanço hidráulico das UHEs em cascata foi mostrado na planilha Balanço Hidráulico, conforme Figura 7.9.




Figura 7.9 - Interface da Planilha Balanço Hidráulico

A Figura 7.10 mostra todas as informações do programa otimizado, apresentado na Planilha Tabelas.

Parâmetros fixos

Turbinagem (m3/s)		Vertimento (m3/s)		Geração (MW)		Qtde de UG	
UAS	1209	USB	250	UAS	202,5	USB	6
USU	0	ULG	0	USU	0	ULG	6
USD	0			USD	0	UXG	6
UST	1209			UST	952,7		

		Turbinagem (m3/s)				Geração (MW)				Qtde UG	Reservatório (hm3)		
		USB	ULG	USQ	UXG	USB	ULG	USQ	UXG	USQ	ULG	USQ	UXG
1	00h00	2264	2364	1171	2365	549	1103	1226	2607	4	1220	3765	5440
2	01h00	2203	2242	1102	2299	533	1024	1148	2529	4	1221	3765	5440
3	02h00	2173	2181	1069	2267	526	986,2	1110	2491	4	1222	3765	5440
4	03h00	2161	2156	1056	2255	523	970,6	1094	2475	4	1222	3765	5440
5	04h00	2175	2185	1071	2269	526	988,4	1112	2493	4	1223	3765	5440
6	05h00	2132	2096	1024	2226	515	934,6	1058	2440	4	1223	3765	5440
7	06h00	2174	2183	1070	2268	526	987,5	1111	2492	4	1224	3765	5440
8	07h00	2283	2401	1193	2386	554	1126	1250	2631	4	1224	3766	5440
9	08h00	2498	2688	1407	2591	608	1290	1468	2849	5	1225	3766	5440
10	09h00	2671	2779	1523	2732	651	1334	1598	2979	5	1226	3766	5440
11	10h00	2738	2817	1569	2792	668	1350	1648	3029	5	1228	3766	5440
12	11h00	2687	2788	1533	2746	655	1337	1610	2991	5	1229	3766	5440
13	12h00	2565	2722	1451	2644	625	1307	1518	2899	5	1230	3766	5440
14	13h00	2683	2786	1530	2742	654	1336	1606	2987	5	1231	3766	5440
15	14h00	2808	2859	1617	2857	686	1367	1700	3081	5	1232	3766	5440
16	15h00	2812	2861	1620	2861	687	1368	1703	3084	5	1233	3765	5440
17	16h00	2710	2801	1549	2766	661	1343	1626	3007	5	1234	3765	5440
18	17h00	2703	2797	1544	2760	659	1341	1621	3002	5	1235	3765	5440
19	18h00	2914	2925	1692	2960	712	1393	1777	3157	5	1236	3765	5440
20	19h00	2898	2915	1681	2946	708	1390	1766	3147	5	1237	3765	5440
21	20h00	2729	2812	1562	2783	666	1348	1641	3022	5	1238	3765	5440
22	21h00	2797	2852	1609	2846	683	1365	1691	3072	5	1239	3765	5440
23	22h00	2593	2737	1470	2666	632	1314	1539	2920	5	1240	3765	5440
24	23h00	2350	2541	1291	2462	571	1211	1335	2716	5	1241	3765	5440

Figura 7.10 - Interface da Planilha Tabelas

8 CONCLUSÃO

Essa dissertação de mestrado abordou o problema de despacho através de um modelo matemático que maximiza a eficiência energética das UHE levando em consideração as restrições operativas traduzidas em termos dos níveis dos reservatórios, do engolimento das turbinas, da meta de geração e da defluência das UHE.

O modelo proposto foi dividido em duas etapas no qual as soluções obtidas na Etapa 1 atenderam a coordenação hidráulica entre as UHE e a carga total da cascata, mantendo os níveis de seus reservatórios dentro do permitido.

Nessa etapa foi utilizada uma formulação mais simplificada na qual a solução é encontrada com mais rapidez, mesmo sendo um subótimo, não ocasionando um problema já que na Etapa 2 esta solução é corrigida. Esta simplificação ocasionou uma vantagem do ponto de vista computacional com uma rápida solução.

A Etapa 2 trata de um problema biobjetivo, pois ele busca maximizar a eficiência e minimizar o número de partidas e paradas de uma UHE em particular. Esta etapa foi estruturada em duas fases que se mostrou adequada, pois permitiu tratar de forma eficiente as restrições das variáveis inteiras, o número de UG a serem despachadas e a geração das UHE.

As soluções obtidas nesta Etapa 2 referem-se às combinações das UG, juntamente com as suas eficiências e geração de cada UG. Um conjunto de soluções não dominadas também é adquirido nessa etapa, fornecendo quais UG estarão ativas a cada hora. Em ambas as fases os AGs foram utilizados em sua resolução.

O algoritmo genético é uma poderosa ferramenta de otimização que vem sendo utilizado com muita frequência na solução de problemas análogos ao trabalho proposto. A eficiência do seu uso na simulação deste trabalho evidenciou uma descoberta apropriada do despacho de máquinas. O resultado alcançado com o seu uso foi uma grande diversidade de soluções com características de partidas e paradas e eficiência distintas de maneira que a melhor solução será encontrada dependendo da prioridade do problema.

O tempo de execução foi de 2564 segundos, razoável para uma análise *offline*, permitindo rapidamente analisar diferentes cenários de operação, fornecendo a solução em termos de despacho de geração e também de despacho de máquinas (partidas/paradas).

Dependendo das condições adotadas pelo problema, este modelo pode vir a sofrer alguns ajustes em sua implementação, de modo que os resultados obtidos apresentem resultados não eficientes.

A implementação do problema foi desenvolvida em dois programas computacionais: *Excel* e o *MATLAB*. Este ambiente computacional proporcionou uma implementação favorável ao problema proposto, devido às restrições operativas adotadas, agilidade no seu desenvolvimento e no favorecimento da inserção de dados.

Esse trabalho é um resultado de um projeto de Pesquisa e Desenvolvimento (P&D), estabelecido entre a UNICAMP e a CHESF por meio da ANEEL durante dois anos, no qual o contratante obteve resultados benéficos para a sua utilidade.

A aplicabilidade deste modelo pode ser utilizada para a otimização de outras UHE em cascatas. Por fim, esta dissertação buscou otimizar a operação diária das UHE em cascata para obter ganhos e eficiência, reduzindo a necessidade da construção de novas UHE para o atendimento da demanda crescente.

8.1 Sugestão para trabalhos futuros

Um fator interessante que se pode evidenciar de perspectiva futura para diversos trabalhos é a utilização de outras ferramentas na resolução da formulação proposta, no sentido de comparar resultados, ganhos de eficiência e tempo de resolução. Tais métodos de resolução estão ligados às tendências das técnicas de programação não linear inteira (PNL) ou com a computação evolutiva.

Outro aspecto relevante a ser considerado é a existência de uma mudança na regulamentação ou na metodologia de despacho durante o planejamento da operação da UHE. Outrossim a mudança ocasionará na implementação e nos resultados obtidos.

REFERÊNCIAS

AARTS, E. H.; KORST., J. **Simulated Annealing and Boltzmann Machines - A Stochastic Approach to Combinatorial Optimization and Neural Computing**. [S.l.]: John Wiley & Sons, 1989.

ABIDO, M. A. Multiobjective evolutionary algorithms for electric power dispatch problem. **IEEE Transactions on Evolutionary Computation**, v. 10, n. 3, p. 315–329, 2006.

ALANDER, J. T. On optimal population size of genetic algorithms. **IEEE Computer Society Press**, p. 65 – 70, 1992.

ANEEL. **Atlas de energia elétrica do Brasil/Agência Nacional de Energia Elétrica (Brasil)**. 2008.

_____. **Banco de Informações de Geração**. 2010. Disponível em:
<http://www.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.asp>. Acesso em:
Maio de 2010.

ARM, V. **UHE Sobradinho: Troca dos cames antigos nas cinco máquinas com execução de ensaios índex**. [S.l.], 2003.

ATMAR, W. Notes on the simulation of evolution. **IEEE Transactions Neural Networks**, p. 130 – 148, 1994.

AVILA, S. L. **Algoritmos Genéticos Aplicados na Otimização de Antenas Refletoras**. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2002.

BACK, T. **Evolutionary Algorithms in Theory and Practice: Evolution Strategies, Evolutionary Programming, Genetic Algorithms**. [S.l.]: Oxford University Press, 1996.

BACK, T.; FOGEL, D. B.; MICHALEWICZ, Z. Handbook of evolutionary computation. **Institute of Physics Publishing and Oxford University Press**, 1997.

BACK, T.; HAMMEL, U.; SCHWEFEL, H. P. Evolutionary computation: Comments on the history and current state. **IEEE Transactions on Evolutionary Computation**, v. 1, p. 3 –17, 1997(a).

BELPIEDE, D. **Aplicação de algoritmos evolutivos para a otimização do fluxo de potência em sistemas de subtransmissão de energia elétrica**. Dissertação (Mestrado) — Escola Politécnica de São Paulo, 2006.

BENNATON, J. F. **O que é otimizar?** Abril 2001. Disponível em:
<http://www.lps.usp.br/neo/jocely/que_e_otimizar.htm>.

BIELLI, M.; CARAMIA, M.; CAROTENUTO, P. Genetic algorithms in bus network optimization. **Transportation Research, Parte C**, v. 10, p. 19 –34, 2002.

BRUN, A. L. Apostila epac - encontro paranaense de computação. Disponível em:
[http://www.fag.edu.br/professores/suzan/Inteligimestre/MC01\(AG\).PDF](http://www.fag.edu.br/professores/suzan/Inteligimestre/MC01(AG).PDF). Acessado em 10 novembro 2009. 2000.

CALAINHO, J. A. L. et al. Cavitação em turbinas hidráulicas do tipo francis e kaplan no brasil. In: **XV SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica**. Foz do Iguaçu, Brasil: [s.n.], 1999.

COELLO, C. A. C.; LAMONT, G. B.; Van Veldhuizer, D. A. **Evolutionary Algorithm for Solving Multi-Objective Problems**. 2. ed. [S.l.]: Springer, 2007.

COLNAGO, G. R. **Modelo de despacho ótimo com tratamento individual de unidades geradoras em usinas hidrelétricas**. Dissertação (Mestrado) — Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2007.

CONALGO, G.; BARROS, P. Multiobjective dispatch of hydrogenerating units using a two-step genetic algorithm method. **IEEE Congress on Evolutionary Computation**, p. 2554 – 2560, 2009.

CORREIA, D. **Algoritmos Genéticos e Elementos Finitos na Síntese de Dispositivos Fotônicos**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 2002.

DARWIN, C. **On the origin of species by means of natural selection**. London: John Murray, 1859.

DEB, K. **Multi-Objective Optimization using Evolutionary Algorithms**. [S.l.]: John Wiley & Sons, Inc, 2001.

EHRGOTT, M. **Multicriteria Optimization**. 2. ed. Berlin: Springer, 2005.

ELETROENERGÉTICOS, L. de Coordenação da Operação de S. **Hydrolab Engenharia e Consultoria**. [S.l.], Fevereiro 2006.

ENCINA, A. S. A. **Um modelo de Otimização do Despacho de Máquinas em Usinas Hidrelétricas**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, 1999.

ENCINA, A. S. A. **Despacho Ótimo de Unidades Geradoras Em Sistemas Hidrelétricos Via Heurística Baseada Em Relaxação Lagrangeana e Programação Dinâmica**. Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 2006.

ENCINA, A. S. A. et al. Despacho Ótimo de unidades geradoras em usinas hidrelétricas. In: **IX Simpósio de Especialistas Em Planejamento Da Operação e Expansão Elétrica**. Rio de Janeiro: [s.n.], 2004.

_____. Unit commitment of hydro dominated systems. **International Journal of Emerging Electric Power Systems**, v. 9, n. 4, 2008.

ENCINA, A. S. A.; OHISHI, T.; SOARES, S. Optimal dispatch of generating units of the itaipú hydroelectric plant. **IEEE Transactions on Power Systems**, v. 17, p. 154–158, 2002.

EPE. **Plano Nacional de Energia 2030**. 2007.

_____. **Plano Decenal de Expansão de Energia 2008/2017**. Rio de Janeiro, 2009.

ESCOBAR, R. L. **Otimização de Parâmetros de Projeto de Sistemas Mecânicos através de Algoritmo Genético Multi-Objetivos**. Dissertação (Mestrado) — Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2007.

ESTEVES, P. P. I.; DINIZ, A. L.; SAGASTIZÁBAL, C. A. A mathematical model for the efficiency curves of hydroelectric units. In: **X Simpósio de Especialistas Em Planejamento Da Operação e Expansão Elétrica**. Florianópolis, Brasil: [s.n.], 2006.

EXCEL, M. **User's Guide**. [S.l.], 2000. [Http://pctraining.hr.state.or.us/Docs/ex-1.pdf](http://pctraining.hr.state.or.us/Docs/ex-1.pdf).

FERREIRA, L. R. M. **Otimização da Operação Energética do Sistema Hidrelétrico do Rio Iguaçu**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 1991.

FILHO, F. O. M. M. **Aplicação de modelos de estimação de fitness em algoritmos genéticos**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 2005.

FILHO, M. de A. L. **Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por algoritmos genéticos**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 2006.

FINARDI, E. C.; SILVA, E. L. D. Unit commitment of single hydroelectric plant. **Electric Power Systems Research**, v. 75, p. 116 – 123, 2005.

FOGEL, D. B. An introduction to simulated evolutionary computation. **IEEE Transactions on Neural Networks**, v. 5, p. 3 – 14, 1994.

FOGEL, L. J.; OWENS, A. J.; WALSH, M. J. Application of evolutionary programming. **Record of the IEEE Systems Science and Cybernetics Conference**, 1966.

FORTUNATO, L. A. M. et al. **Introdução ao Planejamento da Expansão e Operação de Sistemas de Produção de Energia Elétrica**. [S.l.]: Eletrobrás, 1990.

G., O. R. de A. **Aplicação de Algoritmos Genéticos na Determinação de Cava Final e Sequenciamento de Lavra em Minas a Céu Aberto**. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, 2007.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. [S.l.]: Kluwer Academic Publishers, 1989.

HAUPT, R. L.; HAUPT, S. E. **Practical Genetic Algorithms**. 2. ed. [S.l.: s.n.], 2004.

HERRERA, F.; LOZANO, M.; VERDEGAY, J. L. Tackling real-coded genetic algorithms: Operators and tools for behavioural analysis. In: _____. [S.l.]: Springer, 1998. v. 12, cap. Artificial Intelligence Review, p. 265 – 319.

HOLLAND, H. J. **Adaptation in Natural and Artificial Systems**. [S.l.]: The University of Michigan Press, 1975.

HOLLAND, J. Outline for a logical theory of adaptative systems. **JACM**, v. 9, p. 297 – 314, 1962.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. 2. ed. [S.l.]: MIT Press, 1992.

HOUCK, C. R.; KAY, M. A.; JONES, J. **A genetic algorithm for function optimization: a Matlab implementation**. [S.l.]: ACM Transactions on Mathematical Software, 1996.

IEA. **Key Word Energy Statics**. [S.l.]: International Energy Agency, 2010.

JONG, K. A. de. **An Analysis of the Behaviour of a Class of Genetic Adaptative System**. Tese (Doutorado) — University of Michigan, Ann Arbor, 1975.

KADOWAKI, M. et al. Um sistema de apoio à decisão para a programação diária da operação do sistema interligado nacional. **Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE)**, 2007.

KAZAY, H. F. **O Planejamento da Expansão da Geração do Setor Elétrico Brasileiro Utilizando os Algoritmos Genéticos**. Dissertação (Mestrado) — Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia - COPPE, Universidade Federal do Rio de Janeiro, 2001.

KHATAMI, S.; BREADNER, J.; MEECH, J. A. Unit commitment for bc-hydro's mica dam generating plant using a genetic algorithm approach. In: **3rd International Conference on IPMM**. Richmond: [s.n.], 2001.

KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. **Reliability Engineering and System Safety**, v. 91, p. 992–1007, 2006.

LACERDA, E. G. M.; CARVALHO, A. C. P. L. **Introdução aos Algoritmos Genéticos**. [S.l.]: Universidade Federal do Rio Grande do Sul, 1999.

LARSEN, O. **Construção de Atributos x-of-n usando Algoritmos Genéticos**. Dissertação (Mestrado) — Setor de Informática Aplicada, Universidade Católica do Paraná/PR., 2002.

LINDEN, R. **Algoritmos Genéticos: Uma Importante Ferramenta da Inteligência**

Computacional. [S.l.]: Brasport, 2006.

_____. **Algoritmos Genéticos.** 2. ed. [S.l.]: Brasport, 2008.

LOPES, H. Algoritmos genéticos em projetos de engenharia: aplicações e perspectivas futuras. In: **Anais do SBAI'99 - 4o. Simpósio Brasileiro de Automação Inteligente.** [S.l.: s.n.], 1999. p. 64 – 74.

LOPES, H. S.; SANTOS, A. F.; Gebara Junior, M. Cinemática inversa de trajetórias de manipuladores robóticos redundantes utilizando algoritmos genéticos com redução progressiva do espaço de busca. **VII SBAI / II IEEE LARS**, 2005.

LOPES, H. S.; SOUZA, A. A. A. de; Neves Júnior, F. Sistema de avaliação da rede secundária de distribuição utilizando algoritmos genéticos. **Revista Espaço Energia**, v. 5, p. 34 – 41, 2006.

LUENBERGER, D. G. **Linear and Nonlinear Programming.** Reading, Massachusetts: Addison-Wesley, 1986.

MATLAB. **User's Guide.** [S.l.], 2010.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs.** [S.l.]: Springer, 1996.

MICHALEWICZ, Z.; SCHOENAEUR, M. Evolutionary algorithms for constrained parameter optimization problems. **Evolutionary Computation**, v. 4, n. 1, p. 1 – 32, 1996.

MIRANDA, M. N. de. Algoritmos genéticos: Fundamentos e aplicações. Grupo de Teleinformática e Automoção, Universidade Federal do Rio de Janeiro, 2007. Disponível em: <http://www.gta.ufrj.br/marcio/genetic.html>. Acessado em 10 de novembro 2008. 2007.

NB-228. **Ensaio de Recepção de Turbinas Hidráulicas.** [S.l.], 1974.

NILSSON, O.; SJELVGREN, D. Hydro unit start-up costs and their impact on the short term scheduling strategies of swedish power producers. **IEEE Transactions on Power Systems**, v. 12, p. 38 – 43, 1997.

NILSSON, O.; SÓDER, L.; SJELVGREN, D. Integer Modelling of Spinning Reserve Requirements in Short Term Scheduling Hydro Systems. **IEEE Transactions on Power Systems**, v. 13, n. 3, p. 959 – 964, 1998.

OHISHI, T. et al. Otimização do despacho das máquinas das usinas do rio paranapanema. In: **II Congresso de Inovação Tecnológica Em Energia Elétrica**. [S.l.: s.n.], 2001.

ONS. **Norma de Operação - Controle da Geração em Operação Normal -Submódulo 10.8**. [S.l.], 2009. Disponível em: www.ons.org.br. Acesso em: Outubro de 2006.

PACHECO, M. A.; MAFRA, S. A.; MENEZES, I. F. Genetic algorithm optimization for mooring systems. **International Conference on Intelligence Engineering Systems**, 2001.

PACHECO, M. A. C. Algoritmos genéticos: Princípios e aplicações. ICA: Laboratório de Inteligência Computacional Aplicada. Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro. Disponível em: <http://www.ica.ele.puc-rio.br/Downloads/38/CE-Apostila-Comp-Evol.pdf>. Acessado em 10 de novembro de 2009. 1999.

PETROVIC, D.; MORSHED, M.; PETROVIC, S. Genetic algorithm based scheduling of radiotherapy treatments for cancer patients. **Conference on Artificial Intelligence in Medicine-AIME 2009**, p. 101 – 105, 2009.

RECHENBERG, I. Cybernatic solution path of an experimental problem. In: **Library Translation 1122**. [S.l.: s.n.], 1965.

REEVES, C. R. Using genetic algorithms with small populations. In: **Forrest S (ed) Proceedings**

of the 5th international conference on genetic algorithms, p. 92 – 99, 1993.

REIS, L. F. R.; AKUTSU, J. Estratégias operacionais para sistemas de reservatórios via algoritmos genéticos(ags). **Revista da Associação Brasileira de Recursos Hídricos**, 2002.

RESENDE, S. O. **Sistemas Inteligentes - Fundamentos e Aplicações**. [S.l.]: Manole, 2003.

RODRIGUES, R. N.; FINARDI, E. C.; SILVA, E. L. da. Alocação de unidades hidrelétricas no problema da programação da operação energética utilizando relaxação lagrangeana e lagrangeano aumentado. **Revista Controle & Automação**, v. 17, n. 2, p. 155 –166, 2006.

ROSENBERG, R. S. **Simulation of genetic populations with biochemical properties**. Tese (Doutorado) — University of Michigan, Ann Arbor, Michigan, USA, 1967.

RUDOLF, A.; BAYRLEITHNER, R. A genetic algorithm for solving the unit commitment problem of a hydro-thermal power system. **IEEE Transactions on Power System**, v. 14, p. 1460 – 1468, 1999.

SALMAZO, C. T. **Modelo de Otimização Eletro-Energérgico de Curto Prazo (Pré-Despacho) Aplicado Ao Sistema Copel**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 1997.

SANTOS, E. F.; OHISHI, T. A hydro unit commitment model using genetic algorithm. In: **Congress on Evolutionary Computation**. [S.l.: s.n.], 2004. v. 2, p. 1368–1374.

SANTOS, E. F. D. **Um modelo de pré-despacho em usinas hidrelétricas usando algoritmos genéticos**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, 2001.

SANTOS, E. F. D. et al. Um critério de desempenho para o despacho ótimo de unidades geradoras. **Em III Simpósio de Especialistas Em Operação de Centrais Hidrelétricas**, 2002.

SBALZARINIY, I. F.; MULLERY, S.; KOUMOUTSAKOSYZ, P. Multiobjective optimization using evolutionary algorithms. **Center for Turbulence Research ,Proceedings of the Summer Program**, p. 63–74, 2000.

SCHAFFER, J. D. **Multiple Objective Optimization with Vector Evaluated Genetic Algorithms**. Tese (Doutorado) — Vanderbilt University, Nashville, Tennessee, 1984.

SILVA, E. E. **Otimização de Estruturas de Concreto armado Utilizando Algoritmos Genéticos**. Dissertação (Mestrado) — Universidade de São Paulo, 2001.

SIVANANDAM, S. N.; DEEPA, S. N. **Introduction to Genetic Algorithms**. [S.l.]: Springer, 2008.

SOARES, S.; SALMAZO, C. T. Minimum loss predispatch model for hydroelectric power plant systems. **IEEE Transactions on Power Systems**, v. 12, n. 3, p. 1220 – 1228, 1997.

SOUZA, Z. de; SANTOS, A. H. M.; BORTONI, E. da C. **Centrais Hidrelétricas: Estudos para Implantação**. Rio de Janeiro: Centrais Hidrelétricas Brasileiras S. A. - ELETROBRÁS, 1999.

SRINIVAS, M.; PATNAIK, L. M. Genetic algorithms: a survey. **IEEE Computer**, v. 27, p. 17 – 27, 1994.

SZUVOVIVSK, I. **Alocação Simultânea de Bancos de Capacitores e Reguladores de Tensão em Sistemas de Distribuição Usando Algoritmos Genéticos e Fluxo de Potência Ótimo**. Dissertação (Mestrado) — Setor de Tecnologia, Universidade Federal do Paraná, 2008.

TAKAHASHI, L. **Abordagens de Sistemas Inteligentes para a solução do problema de despacho econômico de geração**. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica de Bauru, Universidade Estadual Paulista, 2004.

TOLMASQUIM, M.; GUERREIRO, A.; GORINI, R. Matriz energética brasileira: Uma

prospectiva. **Novos Estudos** 79, v. 3, p. 47 – 69, Novembro 2007.

TORRES, A. C. S. **Torres** **Determinação de Rotas Ótimas de Ônibus Urbanos Utilizando Algoritmo Genético**. Dissertação (Mestrado) — Faculdade de Tecnologia, Universidade de Brasília., 2003.

VILLASANTI, C.; LUCKEN, C. V.; BARÁN, B. Dispatch of hydroelectric generating units using multi-objective evolutionary algorithm. In: **IEEE/PES Transmission & Distribution Conference & Exposition: Latin America**. [S.l.: s.n.], 2004. p. 929–934.

YALCINOZ, T.; ALTUN, H. Power economic dispatch using a hybrid genetic algorithm. **IEEE Power Engineering Letters, IEEE Power Engineering Review**, v. 21, n. 3, p. 59–60, 2001.

ZITZLER, E.; THIELE, . L. **An evolutionary algorithm for multiobjective optimization: The strength Pareto approach**. Zürich, Switzerland, 1998a.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach. **IEEE Transactions on Evolutionary Computation**, v. 3, n. 4, p. 257–271, 1999.