



OTIMIZAÇÃO DA OPERAÇÃO DIÁRIA DE USINAS HIDRELÉTRICAS EM CASCATA UTILIZANDO METAHEURÍSTICAS

Carlos Augusto Machado Gomes

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Djalma Mosqueira Falcão

Rio de Janeiro

Junho de 2018

OTIMIZAÇÃO DA OPERAÇÃO DIÁRIA DE USINAS HIDRELÉTRICAS EM
CASCATA UTILIZANDO METAHEURÍSTICAS

Carlos Augusto Machado Gomes

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA
(COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Djalma Mosqueira Falcão, Ph.D.

Prof. Carmen Lucia Tancredo Borges, D.Sc.

Prof. Vitor Hugo Ferreira, D. Sc.

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2018

Gomes, Carlos Augusto Machado

Otimização da Operação Diária de Usinas Hidrelétricas em Cascata utilizando Metaheurísticas/
Carlos Augusto Machado Gomes – Rio de Janeiro: UFRJ/COPPE, 2018.

XII, 110 p. il.; 29,7 cm

Orientador: Djalma Mosqueira Falcão

Dissertação (Mestrado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2018.

Referências Bibliográficas: p. 107-110.

1. Otimização da operação diária 2. Usinas Hidrelétricas em cascata 3. Metaheurísticas. I. Falcão, Djalma Mosqueira II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

AGRADECIMENTOS

Primeiramente agradeço a Deus por me permitir concluir mais esta etapa de minha vida.

A meus pais, Murilo (*in memoriam*) e Maria Irene pela dedicação incondicional na minha educação e trajetória, meus maiores incentivadores e exemplos.

Ao Professor Djalma Mosqueira Falcão pela oportunidade e honra de sua orientação. Agradeço a confiança, ensinamentos e inspiração, sem os quais este trabalho não seria possível.

Aos professores do Programa de Engenharia Elétrica da COPPE pela notável contribuição em minha formação.

Aos Amigos do LASPOT, que tornaram esta caminhada mais prazerosa. Obrigado por compartilharem bons momentos.

À Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES e a Fundação Coordenação de Projetos de Pesquisa e Estudos Tecnológicos, COPPETEC, pelo suporte financeiro.

À Radix Engenharia e Software e à CERAN – CIA Energética Rio das Antas pelo auxílio, colaboração e suporte financeiro. Este trabalho foi conduzido como parte do projeto de P&D ANEEL, proposto pela CERAN – CIA Energética Rio das Antas. O projeto tem como executora a Radix em parceria com a COPPE/UFRJ.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

OTIMIZAÇÃO DA OPERAÇÃO DIÁRIA DE USINAS HIDRELÉTRICAS EM CASCATA UTILIZANDO METAHEURÍSTICAS

Carlos Augusto Machado Gomes

Junho/2018

Orientador: Djalma Mosqueira Falcão

Programa: Engenharia Elétrica

Este trabalho apresenta o desenvolvimento de um modelo para a otimização da programação da operação diária de usinas hidrelétricas em cascata, utilizando metaheurísticas. O planejamento da operação diária de usinas visa definir os níveis de geração e o despacho de unidades geradoras de forma a atender um padrão de geração estabelecido pelas demais etapas de planejamento. O sistema hidrelétrico foi considerado de forma detalhada, com representação individual de unidades geradoras, curvas de eficiência de máquinas e operação dos reservatórios. O objetivo do problema é definir uma operação ótima, definindo o despacho em nível de máquinas. Trata-se de um problema de otimização de característica inteira-mista, com variáveis reais e binárias. A solução proposta ao problema foi através de métodos metaheurísticos, cuja característica permite resolver o problema de forma genérica, permitindo a replicação das soluções apresentadas em cenários de otimização de característica semelhante.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

OPTIMIZATION OF CASCADE HYDRO POWER PLANTS DAILY OPERATION
USING METAHEURISTICS

Carlos Augusto Machado Gomes

June/2018

Advisor: Djalma Mosqueira Falcão

Department: Electrical Engineering

This work presents the development of an optimization model for the daily scheduling operation of cascade hydropower plants using metaheuristics. The scheduling of the day-to-day operation of hydropower plants aims at defining the unit commitment and the generation levels in order to meet a generation pattern established by the other planning stages, reducing the amount of water used. The hydroelectric system was considered with individual representation of generating units, machines' efficiency curves and operation of reservoirs. The objective of the problem is to define an optimal operation, defining the dispatch at machine levels. It is an integer-mixed optimization problem, with real and binary variables. The solution proposed to the problem was through metaheuristic methods, whose characteristic allows solving the problem generically, applicable to any similar system, allowing the replication of the solutions presented in other similar optimization scenarios.

SUMÁRIO

LISTA DE FIGURAS.....	IX
LISTA DE TABELAS.....	XI
CAPÍTULO 1 INTRODUÇÃO	1
1.1 MOTIVAÇÃO	1
1.2 REVISÃO BIBLIOGRÁFICA	3
1.3 OBJETIVOS.....	4
1.4 PUBLICAÇÕES.....	4
1.5 ESTRUTURA DO TRABALHO	5
CAPÍTULO 2 PLANEJAMENTO DA GERAÇÃO ELÉTRICA.....	6
2.1 INTRODUÇÃO	6
2.2 PLANEJAMENTO DA OPERAÇÃO DO SISTEMA ELÉTRICO BRASILEIRO.....	7
2.2.1 Critérios do Planejamento da Operação	9
2.2.2 Etapas do Planejamento da Geração.....	10
CAPÍTULO 3 FORMULAÇÃO MATEMÁTICA.....	16
3.1 INTRODUÇÃO	16
3.2 MODELAGEM DE UNIDADES HIDRELÉTRICAS	17
3.2.1 Descrição dos Componentes	17
3.2.2 Formulação da Geração Hidrelétrica.....	18
3.2.3 Perdas Hidráulicas.....	20
3.2.4 Perdas Mecânicas e Elétricas	21
3.2.5 Curvas de Eficiência das Turbinas	21
3.2.6 Restrições de Operação das Turbinas	22
3.3 OPERAÇÃO DO RESERVATÓRIO DE USINAS HIDRELÉTRICAS.....	24
3.4 FORMULAÇÃO DO PROBLEMA.....	26
3.4.1 Despacho Energético Ótimo.....	27
3.4.2 Alocação de Unidades.....	28
3.4.3 Otimização da Geração Diária de um Conjunto de Usinas Hidrelétricas em Cascata	28
CAPÍTULO 4 METAHEURÍSTICAS.....	32
4.1 INTRODUÇÃO	32
4.2 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS.....	34

4.2.1	Algoritmo PSO Padrão.....	35
4.2.2	Algoritmo PSO com Representação Binária	37
4.2.3	Topologia de Vizinhaça para o PSO	38
4.2.4	PSO Unificado (UPSO).....	40
4.2.5	UPSO com representaçaõ hıbrida.....	40
4.3	ALGORITMO GENÉTICO.....	42
4.3.1	Estrutura de um Algoritmo Genético	44
4.3.2	Seleçaõ	45
4.3.3	Elitismo	47
4.3.4	Operadores Genéticos.....	47
4.4	ALGORITMO DE EVOLUÇAõ DIFERENCIAL.....	51
4.4.1	Operadores Genéticos.....	52
4.4.2	Evoluçaõ Diferencial Aprimorado	55
CAPÍTULO 5 IMPLEMENTAÇAõ COMPUTACIONAL.....		56
5.1	INTRODUÇAõ	56
5.2	SISTEMA TESTE.....	57
5.2.1	Dados do Sistema	57
5.2.2	Cenário Base	61
5.3	ESTRATÉGIA DE SOLUCAõ.....	62
5.3.1	Representaçaõ das Soluçaões Candidatas	63
5.3.2	Funçaõ Objetivo e Restrições	68
5.4	SIMULAÇÕES.....	71
5.4.1	Ajuste dos M étodos	71
5.4.2	Comparaçaõ entre M étodos.....	81
5.4.3	Cenários Avaliados	85
CAPÍTULO 6 CONCLUSõES.....		104
6.1	TRABALHOS FUTUROS.....	106
REFERÊNCIAS BIBLIOGRÁFICAS		107

LISTA DE FIGURAS

FIGURA 2.1 – DILEMA DA OPERAÇÃO DE SISTEMAS HIDROTÉRMICOS.	9
FIGURA 2.2 - CADEIA DE MODELOS DE PLANEJAMENTO DE OPERAÇÃO DO SIN, DESENVOLVIDOS PELO CEPEL. (ADAPTADO DE [1]).....	11
FIGURA 3.1- ESQUEMA SIMPLIFICADO DOS ELEMENTOS DE UMA USINA HIDRELÉTRICA	17
FIGURA 3.2 – VARIÁVEIS DA ETAPA DE PRODUÇÃO DE ENERGIA HIDRELÉTRICA.	18
FIGURA 3.3 – CURVA COLINA DE UMA TURBINA HIDRÁULICA.....	22
FIGURA 3.4 – REGIÕES DE OPERAÇÃO DAS TURBINAS HIDRELÉTRICAS, PARA DIFERENTES FAIXAS DE POTÊNCIA, COM INDICAÇÃO DAS ZONAS PROIBITIVAS DE OPERAÇÃO.	23
FIGURA 3.5 – ESQUEMA REPRESENTATIVO DE USINAS HIDRELÉTRICAS EM CASCATA.	25
FIGURA 4.1 – ENXAME DE PARTÍCULAS COM AS RESPECTIVAS POSIÇÕES E VELOCIDADES DE UMA DADA ITERAÇÃO, EM UM ESPAÇO DE BUSCA BIDIMENSIONAL.	34
FIGURA 4.2 – FUNÇÃO SIGMOIDE NO INTERVALO $[-8, 8]$	38
FIGURA 4.3 – TOPOLOGIA EM ANEL, RODA E VIZINHANÇA GLOBAL.	39
FIGURA 4.4 – FLUXOGRAMA DE EXECUÇÃO DO MÉTODO PSO/UPSO	42
FIGURA 4.5 – FLUXOGRAMA DE EXECUÇÃO DO MÉTODO ALGORITMO GENÉTICO	45
FIGURA 4.6 – MÉTODO DE SELEÇÃO POR TORNEIO.....	46
FIGURA 4.7 – MÉTODO DA ROLETA BASEADO EM APTIDÃO RELATIVA	47
FIGURA 4.8 – CRUZAMENTO UNIFORME.	48
FIGURA 4.10 – EXEMPLO DE MUTAÇÃO UNIFORME PARA CODIFICAÇÃO DE VALORES REAIS E BINÁRIOS.....	50
FIGURA 4.11 – FLUXOGRAMA DE EXECUÇÃO DO MÉTODO DE EVOLUÇÃO DIFERENCIAL	52
FIGURA 4.12 – FORMAÇÃO DO VETOR TENTATIVA A PARTIR DA ETAPA DE MUTAÇÃO.	54
FIGURA 5.1 – ESQUEMA DO SISTEMA DE HIDRELÉTRICAS ESTUDADO.....	57
FIGURA 5.2 - CURVA DE DEMANDA – CENÁRIO 1 (CASO BASE).....	62
FIGURA 5.3 – EXEMPLO DA PARCELA REAL DE UM INDIVÍDUO OU SOLUÇÃO.....	65
FIGURA 5.4 – EXEMPLO DA PARCELA BINÁRIA DE UM INDIVÍDUO OU SOLUÇÃO.	67
FIGURA 5.5 – REPRESENTAÇÃO MISTA DE UM INDIVÍDUO OU SOLUÇÃO.....	68
FIGURA 5.6 – MELHOR SOLUÇÃO ENCONTRADA PELO MÉTODO UPSO.	74
FIGURA 5.7 – MELHOR SOLUÇÃO ENCONTRADA PELO MÉTODO AG.	77
FIGURA 5.8 – MELHOR SOLUÇÃO ENCONTRADA PELO MÉTODO DE.....	80
FIGURA 5.9 – EVOLUÇÃO DO VALOR DA FUNÇÃO OBJETIVO DE UMA SOLUÇÃO DE CADA MÉTODO.....	83
FIGURA 5.10 – EVOLUÇÃO DO VALOR DA VAZÃO TOTAL DA DE UMA SOLUÇÃO DE CADA MÉTODO.....	84
FIGURA 5.11 - EVOLUÇÃO DO NÚMERO DE PARTIDAS DE UMA SOLUÇÃO DE CADA MÉTODO.	84
FIGURA 5.12 - SOLUÇÃO PELO MÉTODO UPSO, CENÁRIO 1	86
FIGURA 5.13 - SOLUÇÃO PELO MÉTODO AG, CENÁRIO 1	87
FIGURA 5.14 – SOLUÇÃO PELO MÉTODO DE, CENÁRIO 1.....	87
FIGURA 5.15 - SOLUÇÃO PELO MÉTODO UPSO, CENÁRIO 2	89

FIGURA 5.16 - SOLUÇÃO PELO MÉTODO AG, CENÁRIO 2 .	89
FIGURA 5.17 - SOLUÇÃO PELO MÉTODO DE, CENÁRIO 2	90
FIGURA 5.18 - SOLUÇÃO PELO MÉTODO UPSO, CENÁRIO 3 .	91
FIGURA 5.19 - SOLUÇÃO PELO MÉTODO AG, CENÁRIO 3 .	92
FIGURA 5.20 - SOLUÇÃO 1 PELO MÉTODO DE, CENÁRIO 3 .	92
FIGURA 5.21 - SOLUÇÃO PELO MÉTODO UPSO, CENÁRIO 4.....	94
FIGURA 5.22 - SOLUÇÃO PELO MÉTODO AG, CENÁRIO 4	94
FIGURA 5.23 - SOLUÇÃO PELO MÉTODO DE, CENÁRIO 4	95
FIGURA 5.24 – CURVA DE DEMANDA – CENÁRIO 5.	96
FIGURA 5.25 - SOLUÇÃO PELO MÉTODO UPSO, CENÁRIO 5.....	97
FIGURA 5.26 - SOLUÇÃO PELO MÉTODO AG, CENÁRIO 5.	97
FIGURA 5.27 - SOLUÇÃO PELO MÉTODO DE, CENÁRIO 5.	97
FIGURA 5.28 – CURVA DE DEMANDA – CENÁRIO 6.	98
FIGURA 5.29 - SOLUÇÃO PELO MÉTODO UPSO, CENÁRIO 6.....	99
FIGURA 5.30 - SOLUÇÃO PELO MÉTODO AG, CENÁRIO 6.	99
FIGURA 5.31 - SOLUÇÃO PELO MÉTODO DE, CENÁRIO 6.	99
FIGURA 5.32 – MÉTODO UPSO – NÚMERO DE PARTIDA DIÁRIA DE CADA MÁQUINA LIMITADO.....	100
FIGURA 5.33 – MÉTODO AG – NÚMERO DE PARTIDA DIÁRIA DE CADA MÁQUINA LIMITADO	101
FIGURA 5.34 – MÉTODO DE – NÚMERO DE PARTIDA DIÁRIA DE CADA MÁQUINA LIMITADO	101
FIGURA 5.35 – MÉTODO UPSO – IMPEDIMENTO DE PARADAS DE MÁQUINAS.....	102
FIGURA 5.36 - MÉTODO AG – IMPEDIMENTO DE PARADAS DE MÁQUINAS.....	102
FIGURA 5.37 - MÉTODO DE – IMPEDIMENTO DE PARADAS DE MÁQUINAS.	102

LISTA DE TABELAS

TABELA 5.1 – TEMPO DE DESLOCAMENTO ENTRE AS USINAS	57
TABELA 5.2 – ORDEM DE DESPACHO DAS MÁQUINAS PARA CADA UMA DAS USINAS HIDRELÉTRICAS.	58
TABELA 5.3 – LIMITES MÍNIMOS E MÁXIMOS DE POTÊNCIA PARA CADA TIPO DE UNIDADE GERADORA	58
TABELA 5.4 – COEFICIENTES DE RENDIMENTO DA TURBINA PARA CADA TIPO DE MÁQUINA DO SISTEMA.	58
TABELA 5.5 – COEFICIENTES DE VAZÃO TURBINADA MÁXIMA POR TIPO DE MÁQUINA	59
TABELA 5.6 – COEFICIENTES DE VAZÃO TURBINADA MÍNIMA POR TIPO DE MÁQUINA.....	59
TABELA 5.7 – VOLUMES MÍNIMOS E MÁXIMOS PERMITIDOS NOS RESERVATÓRIOS POR USINA	59
TABELA 5.8 – COEFICIENTES DE COTA A MONTANTE POR USINA	60
TABELA 5.9 – COEFICIENTES DE COTA A JUSANTE POR USINA	60
TABELA 5.10 – VAZÃO DEFLUENTE MÁXIMA E MÍNIMA POR USINA.....	60
TABELA 5.11 – COEFICIENTES DE PERDAS HIDRÁULICAS POR USINA	60
TABELA 5.12 – COEFICIENTES DE EFICIÊNCIA DAS TURBINAS E DOS GERADORES POR TIPO DE MÁQUINA	61
TABELA 5.13 – CONDIÇÕES DE OPERAÇÃO CONSIDERADAS PARA O CASO BASE.	61
TABELA 5.14 – VALORES DA CURVA DE DEMANDA PARA O CASO BASE	62
TABELA 5.15 – DETERMINAÇÃO DA PARCELA REAL.....	65
TABELA 5.16 – DETERMINAÇÃO DA PARCELA BINARIA.	66
TABELA 5.17 – CONDIÇÕES DE ALOCAÇÃO DE UNIDADES ADOTADA COM 2 E 3 BITS.....	66
TABELA 5.18 – REPRESENTAÇÃO MISTA DAS VARIÁVEIS DO PROBLEMA POR INTERVALO DE TEMPO.	67
TABELA 5.19 – COEFICIENTES DE PENALIZAÇÃO ADOTADOS.	70
TABELA 5.20 - NÚMERO DE AVALIAÇÕES DA FUNÇÃO OBJETIVO POR CONDIÇÃO AVALIADA.....	71
TABELA 5.21 – AJUSTES DOS PARÂMETROS DO MÉTODO UPSO	72
TABELA 5.22 – PERCENTUAL DE SOLUÇÕES VIÁVEIS E TEMPO DE SIMULAÇÃO EM DIFERENTES CONDIÇÕES DE POPULAÇÃO E ITERAÇÕES. (MÉTODO UPSO)	73
TABELA 5.23 – MÉDIA DO VALOR DA FUNÇÃO OBJETIVO E VARIAÇÃO MÉDIA DO VALOR DAS SOLUÇÕES EM DIFERENTES CONDIÇÕES DE POPULAÇÃO E ITERAÇÕES (MÉTODO UPSO).....	73
TABELA 5.24 – MELHOR E PIOR SOLUÇÃO EM CADA CONDIÇÃO (MÉTODO UPSO)	73
TABELA 5.25 – CUSTO MÉDIO E NÚMERO MÉDIO DE PARTIDAS DE SOLUÇÕES VIÁVEIS (MÉTODO UPSO)	73
TABELA 5.26 – RESULTADOS PARA A MELHOR SOLUÇÃO ENCONTRADA PELO MÉTODO UPSO.	74
TABELA 5.27 – AJUSTES ESCOLHIDOS PARA O MÉTODO ALGORITMO GENÉTICO.....	75
TABELA 5.28 – PERCENTUAL DE SOLUÇÕES VIÁVEIS E TEMPO DE SIMULAÇÃO EM DIFERENTES CONDIÇÕES DE POPULAÇÃO E ITERAÇÕES. (MÉTODO AG)	75
TABELA 5.29 – MÉDIA DO VALOR DA FUNÇÃO OBJETIVO E VARIAÇÃO MÉDIA DO VALOR DAS SOLUÇÕES EM DIFERENTES CONDIÇÕES DE POPULAÇÃO E ITERAÇÕES (MÉTODO AG).....	76
TABELA 5.30 – MELHOR E PIOR SOLUÇÃO EM CADA CONDIÇÃO (MÉTODO AG)	76
TABELA 5.31 – CUSTO MÉDIO E NÚMERO MÉDIO DE PARTIDAS NAS SOLUÇÕES VIÁVEIS DE CADA CENÁRIO. (MÉTODO AG) ...	76
TABELA 5.32 - RESULTADOS PARA A MELHOR SOLUÇÃO ENCONTRADA PELO MÉTODO AG.	77

TABELA 5.33 – AJUSTES INICIAIS ESCOLHIDOS PARA O MÉTODO EVOLUÇÃO DIFERENCIAL	78
TABELA 5.34 – PERCENTUAL DE SOLUÇÕES VIÁVEIS E TEMPO DE SIMULAÇÃO EM DIFERENTES CONDIÇÕES DE POPULAÇÃO E ITERAÇÕES. (MÉTODO DE).....	78
TABELA 5.35 – MÉDIA DO VALOR DA FUNÇÃO OBJETIVO E TEMPO DE SIMULAÇÃO EM DIFERENTES CONDIÇÕES DE POPULAÇÃO E ITERAÇÕES (MÉTODO DE).....	79
TABELA 5.36 – MELHOR E PIOR SOLUÇÃO EM CADA CONDIÇÃO (MÉTODO DE).....	79
TABELA 5.37 – CUSTO MÉDIO E NÚMERO MÉDIO DE PARTIDAS NAS SOLUÇÕES VIÁVEIS DE CADA CENÁRIO. (MÉTODO DE) ...	79
TABELA 5.38 – RESULTADOS PARA A MELHOR SOLUÇÃO ENCONTRADA PELO MÉTODO DE.	80
TABELA 5.39 – MELHOR SOLUÇÃO ENCONTRADA POR CADA MÉTODO METAHEURÍSTICO.	81
TABELA 5.40 – DESEMPENHO MÉDIO DAS SOLUÇÕES VIÁVEIS: POP=50; 1000 ≤ ITER ≤ 3000	82
TABELA 5.41 – DESEMPENHO MÉDIO DAS SOLUÇÕES VIÁVEIS : POP=100; 1000 ≤ ITER ≤ 3000.....	82
TABELA 5.42 – DESEMPENHO MÉDIO DAS SOLUÇÕES VIÁVEIS : POP=200; 2000 ≤ ITER ≤ 3000.....	83
TABELA 5.43 – CENÁRIO ALTERNATIVO DE VOLUME E VAZÃO INCREMENTAL – CENÁRIO 1.	85
TABELA 5.44 – RESULTADOS PARA O CENÁRIO 1 DE VAZÃO E VOLUME INICIAL	86
TABELA 5.45 – CENÁRIO ALTERNATIVO DE VOLUME E VAZÃO INCREMENTAL – CENÁRIO 2.	88
TABELA 5.46 – RESULTADOS PARA O CENÁRIO 2 DE VAZÃO E VOLUME INICIAL	88
TABELA 5.47 – CENÁRIO ALTERNATIVO DE VOLUME E VAZÃO INCREMENTAL – CENÁRIO 3.	90
TABELA 5.48 – RESULTADOS PARA O CENÁRIO 3 DE VAZÃO E VOLUME INICIAL	91
TABELA 5.49 – CENÁRIO ALTERNATIVO DE VOLUME E VAZÃO INCREMENTAL – CENÁRIO 4.	93
TABELA 5.50 – RESULTADOS PARA O CENÁRIO 4 DE VAZÃO E VOLUME INICIAL	93
TABELA 5.51 – CURVA DE DEMANDA – CENÁRIO 5.	96
TABELA 5.52 – RESULTADOS PARA O CENÁRIO 5.....	96
TABELA 5.53 – CURVA DE DEMANDA – CENÁRIO 6.	98
TABELA 5.54 – RESULTADOS PARA O CENÁRIO 6.....	98
TABELA 5.55 – RESULTADOS PARA LIMITAÇÃO DE UMA PARTIDA DIÁRIA POR MÁQUINA.	100
TABELA 5.56 – RESULTADOS PARA CENÁRIO SEM PARADAS DE MÁQUINAS.	101

CAPÍTULO 1

INTRODUÇÃO

1.1 Motivação

O objetivo de um estudo de planejamento da operação de um sistema de energia elétrica é atender os requisitos de custo, confiabilidade ou consumo ótimo de recursos energéticos. Em sistemas hidrotérmicos, como o sistema brasileiro, o uso correto da energia hidrelétrica, disponível em quantidades limitadas na forma de água nos reservatórios, é um problema de característica bastante complexa. O compromisso entre decisões imediatas e as consequências futuras desta decisão tornam o problema desafiador e evidenciam a importância de um planejamento adequado.

O estudo do planejamento da operação de sistemas elétricos possui três principais horizontes de tempo: planejamento de médio e longo prazo, planejamento de curto prazo e programação da operação diária [1]. O planejamento de longo prazo, médio prazo e de curto prazo, são centralizados no Operador Nacional do Sistema, ONS. Já a programação da operação energética diária, de forma geral, é um problema de operação local por parte das operadoras das usinas [2]. Atualmente o ONS não faz

uso de um modelo que forneça a política ótima de geração para as unidades do sistema para o dia seguinte. O problema de otimização da programação da operação diária consiste em determinar uma configuração ótima de geração que atenda às metas estabelecidas pelo planejamento de curto prazo, sendo o principal foco desta dissertação.

Em geral, as empresas de geração de energia não possuem um planejamento otimizado para a programação da geração diária, sendo a definição da operação ao longo do dia baseada na experiência adquirida de quem as opera. Essa política acarreta em implicações negativas para as empresas geradoras, com a não utilização eficiente de recursos energéticos, o que afeta diretamente nos custos de operação.

Para contornar as implicações de uma operação ineficiente, se buscam cada vez mais formas de otimizar a geração diária do sistema elétrico. Em sistemas hidrotérmicos a otimização do planejamento da geração de energia resulta em redução dos riscos de déficit futuro, riscos de vertimento de água nos reservatórios e conseqüentemente na menor utilização de térmicas, acarretando em um menor custo da energia gerada. Ao longo dos anos, diversos estudos vêm sendo realizados focados na otimização da operação diária. Devido a diferentes formas de abordagem, tipos de sistema e complexidade do problema, este é um campo amplamente vasto a ser explorado e que ainda carece de estudo e de aplicação consolidada. Entretanto, diferentes estudos e abordagens para o planejamento da operação em sistemas hidrelétricos vêm sendo desenvolvidos.

O planejamento da operação de sistemas hidrelétricos em cascata é um problema particular, devido à complexidade de sua modelagem e de sua característica de acoplamento espacial e temporal. Decisões de operação em um reservatório afetam diretamente os níveis dos demais reservatórios a jusante e decisões de armazenamento ou utilização das águas afetam o nível futuro dos reservatórios, podendo acarretar em risco de déficit ou vertimento. Portanto, a operação de um sistema hidrelétrico deve focar, além da operação elétrica, na questão da operação dos reservatórios, sendo um problema de acoplamento “espacial” e “temporal”.

1.2 Revisão Bibliográfica

O estudo de otimização de sistemas hidrotérmicos de energia elétrica vem sendo desenvolvido há longo tempo, resultando em vasta literatura técnica. Em particular, estudos relacionados ao sistema elétrico brasileiro resultaram em uma cadeia de modelos utilizada no planejamento do Sistema Interligado Nacional (SIN).

O problema de despacho ótimo da geração diária em sistemas hidrelétricos não possui uma abordagem unificada, já sendo previamente abordado em alguns trabalhos presentes na literatura. As diferentes abordagens presentes sobre o tema variam de acordo com o tipo de sistema, detalhamento da modelagem e a estratégia de solução adotada. Sistemas hidrelétricos em cascata, como o abordado neste trabalho, possuem uma ainda maior complexidade em sua operação conjunta, sendo mais escassas as fontes de pesquisa neste segmento.

A seguir serão listadas algumas das abordagens dadas ao problema da otimização da operação diária de sistemas hidrelétricos em cascata, encontradas na literatura.

Em [3] foi realizado o planejamento da operação diária de um sistema hidrelétrico em cascata utilizando algoritmo de enxame de partículas otimizado. Neste trabalho o objetivo é minimizar a diferença entre a demanda e a potência gerada, seguindo as restrições de balanço de água e limite dos reservatórios e vazões. As usinas são representadas como modelos equivalentes, não sendo representadas a nível de unidades geradoras. No trabalho realizado em [4], seguindo abordagem semelhante, o objetivo é maximizar a energia total gerada em uma cascata de duas usinas.

Em [5] é também utilizada uma variação do algoritmo de enxame de partículas para a otimização de distribuição de carga, buscando minimizar a quantidade de água utilizada, de forma a atender uma demanda estabelecida. As usinas são representadas de forma equivalente, não sendo representadas a nível de unidade geradora.

Em [6] é utilizada uma variação do PSO para o planejamento ótimo em curto prazo de um conjunto de usinas hidrelétricas em cascata. O sistema não é representado a

nível de unidade geradora e sim a nível de usinas, não sendo considerado o problema de alocação de unidades geradoras.

Em [2] e [1] são também apresentados estudos de otimização da operação diária de usinas hidrelétricas, através de uma modelagem detalhada da função de geração hidrelétrica e das restrições do problema, sendo apresentadas também soluções a nível de unidades geradoras. A solução proposta pelos autores utiliza técnicas de Relaxação Lagrangeana para relaxação das restrições do problema, a fim de obter uma solução viável ao problema.

1.3 Objetivos

O objetivo deste trabalho é desenvolver modelos para a otimização da geração diária de usinas hidrelétricas em cascata. A otimização tem por objetivo reduzir a quantidade de água utilizada durante o dia, atendendo uma demanda energética diária pré-estabelecida. A economia de água permite uma operação mais eficiente, possibilitando maior potencial energético ao longo dos dias de operação.

Este trabalho se propõe a criar uma metodologia de solução para este tipo de problema utilizando técnicas de otimização metaheurísticas. As técnicas aqui apresentadas possuem característica populacional e de número elevado de iterações. A característica dos métodos permite que sejam aplicadas técnicas de computação paralela, reduzindo os tempos de simulação necessários.

A solução proposta visa resolver o problema de alocação das unidades geradoras das usinas ao longo do dia e também o problema de despacho de cada unidade geradora. Busca-se neste trabalho que os resultados obtidos possam ser reproduzidos no ambiente operacional de forma a nortear a operação diária.

1.4 Publicações

Parte dos resultados apresentados neste trabalho está presentes no artigo “*Comparison of Metaheuristics Applied to Cascade Hydro Power Plants*”, aceito para publicação no VII Simpósio Brasileiro de Sistemas Elétricos – SBSE 2018 [7]

1.5 Estrutura do Trabalho

Este trabalho está estruturado da seguinte forma:

O Capítulo 2 apresenta a estrutura de um estudo de planejamento da geração elétrica, com foco para o sistema elétrico brasileiro. São apresentados os principais critérios do planejamento e suas etapas. O problema de planejamento da programação da geração diária de usinas, que não possui um estudo centralizado, é apresentado, sendo sugeridos os alicerces de um modelo de otimização em subsistemas hidrelétricos em cascata.

O Capítulo 3 apresenta a formulação matemática para o modelo de geração hidrelétrica, além da formulação da operação dos reservatórios destas usinas. É também estruturada a formulação matemática do problema de otimização estudado neste trabalho.

O Capítulo 4 apresenta alguns modelos metaheurísticos de otimização, apresentando três principais métodos: Otimização por Enxame de Partículas, Algoritmo Genético e Algoritmo de Evolução Diferencial.

O Capítulo 5 apresenta a estratégia de solução dada ao problema de otimização e os resultados obtidos pelos métodos implementados.

O Capítulo 6 apresenta as principais conclusões e as principais sugestões para desenvolvimentos futuros.

CAPÍTULO 2

PLANEJAMENTO DA GERAÇÃO ELÉTRICA

2.1 Introdução

Sistemas elétricos de potência são subdivididos simplificadaamente em três componentes básicos [8], sendo eles:

- **Geração:** Compreende os elementos produtores de energia elétrica. No caso brasileiro a matriz de geração elétrica é de característica predominantemente hidrotérmica, composto de usinas hidrelétricas e térmicas.
- **Transmissão:** Compreende as linhas de transmissão, que levam energia dos pontos de geração até os pontos de carga. A importância do sistema de transmissão se deve ao fato de possibilitar a existência de fontes de geração distantes dos pontos de consumo, podendo alimentar diferentes pontos do sistema através de fontes de geração distantes.

- **Distribuição:** Compreende o sistema de distribuição da energia dos principais centros de carga até o consumidor final.

Este capítulo apresenta as principais características e etapas de planejamento da geração elétrica em sistemas de potência. Com enfoque no caso brasileiro, serão apresentadas as principais etapas do planejamento energético do sistema brasileiro, com destaque para suas principais características e considerações.

O planejamento da geração elétrica é dividido em duas principais etapas, sendo elas: o planejamento da expansão e o planejamento da operação [1]:

- O planejamento da expansão do setor elétrico brasileiro é da responsabilidade do Ministério de Minas e Energia e realizado através de estudos da Empresa de Pesquisa Energética (EPE). O estudo é de característica de muito longo prazo, em faixas de 10 a 30 anos ou mais. O estudo de planejamento da expansão tem como objetivo elaborar estudos para a determinação ótima de locais e datas para a criação de novas usinas de grande porte e de novas interligações entre regiões, de maneira a atender uma demanda crescente, também estipulada.
- O planejamento da operação consiste em operar de forma ótima as fontes energéticas do sistema elétrico, seguindo também um cronograma de expansão previamente determinado. O horizonte de programação de tal estudo varia de dias até anos de operação, ou seja, estudos de curto prazo até estudos de longo prazo, sendo realizado pelo ONS (Operador Nacional do Sistema).

2.2 Planejamento da Operação do Sistema Elétrico Brasileiro

O Brasil possui um sistema elétrico de características e dimensões único em âmbito mundial. O Sistema Interligado Nacional (SIN) é de característica predominantemente hidrotérmica, ou seja, composto em sua maioria por usinas hidrelétricas e térmicas, no qual as usinas hidrelétricas ocupam cerca de 70% do potencial energético instalado no país [9].

O sistema brasileiro possui outra forte singularidade em relação a outros países que é sua dimensão continental que lhe confere grande complexidade operacional. O sistema brasileiro possui também uma grande variedade de sazonalidade hidrológica entre regiões distintas. Por se tratar de um sistema com grande penetração hidrelétrica, a operação das diferentes usinas permite uma transferência de excedentes de energia entre diferentes partes do país em épocas do ano distintas, permitindo a otimização dos estoques armazenados nos reservatórios das usinas hidrelétricas.

A dificuldade da operação do sistema hidrotérmico, particularmente o caso brasileiro, é resumida nos seguintes fatores [1]:

- É um problema acoplado no tempo: Decisões no presente afetam diretamente as disponibilidades futuras. No caso de hidrelétricas, os níveis dos reservatórios podem ser afetados por decisões mal planejadas, o que pode acarretar em pouca disponibilidade de água e conseqüentemente déficit energético.
- É um problema acoplado no espaço: Principalmente devido a característica em cascata de muitas usinas do sistema e de as usinas concorrerem simultaneamente para o atendimento a demanda.
- É um problema de grande porte: O planejamento conjunto do sistema, que possui um número elevado de usinas, é o problema difícil de tratar em razão do seu elevado número de variáveis e condições.
- É um problema estocástico: As aflúncias futuras em geral são estimadas de forma estocástica, assim como a demanda, o que traz muitas incertezas ao problema.
- É um problema de formulação matemática complexa: O problema possui muitas restrições de operação simultâneas, proveniente de cada ponto de geração do sistema, o que torna o problema de tratamento matemático extremamente complexo.

Em sistemas hidrotérmicos como o sistema brasileiro, o uso correto da energia hidrelétrica, disponível em quantidades limitadas na forma de água nos reservatórios, e a forte relação entre decisões imediatas e as conseqüências futuras desta decisão, tornam

o problema de operação extremamente complexo. A Figura 2.1 mostra o principal no planejamento da tomada de decisões em sistemas hidrotérmicos.

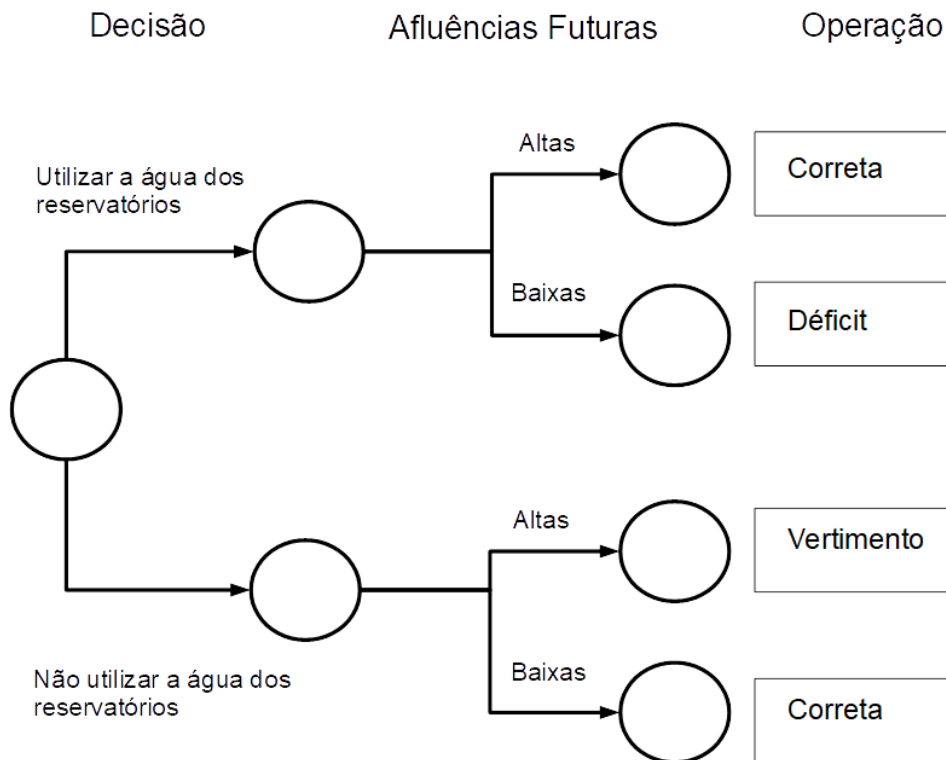


Figura 2.1 – Dilema da operação de sistemas hidrotérmicos. . (Baseado no esquema presente em [10])

A seguir são definidas as principais etapas do planejamento de operação da geração, em todos os seus níveis estratégicos, com foco no caso brasileiro.

2.2.1 Critérios do Planejamento da Operação

Em estudos de planejamento da operação, um ou mais critérios podem ser adotados [1], dentre os quais podemos citar:

- **Minimização dos custos operativos:** O critério de minimização dos custos operativos é o critério básico e clássico em estudos de planejamento da operação, sendo em geral a garantia de confiabilidade e critérios de segurança ambientais adotados como restrições operativas. É o caso adotado no planejamento do sistema elétrico brasileiro.

- **Maximização dos lucros de uma empresa:** O critério de maximização de lucros de uma empresa é adotado quando se deseja determinar a melhor estratégia individual de uma empresa de energia, sendo adotada em estudos específicos das empresas em problemas voltados aos preços da energia.
- **Garantia de confiabilidade do sistema:** A garantia de confiabilidade de um sistema é conflitante com o objetivo de minimização dos custos, podendo ocorrer casos em que o principal foco do planejamento seja incrementar a confiabilidade do sistema.
- **Diminuição dos impactos ambientais:** A diminuição dos impactos ambientais é adotada quando se deseja reduzir, por exemplo, a emissão de poluentes por determinado tipo de usina.

Os critérios podem ser adotados individualmente, ou, o caso mais comum, em conjunto, o que varia de acordo com o interesse de quem realizará o planejamento. Demais critérios podem também ser adotados, variando também a partir da característica do estudo.

2.2.2 Etapas do Planejamento da Geração

No Brasil, o Operador Nacional do Sistema Elétrico (ONS) realiza uma série de atividades para operação centralizada do Sistema Interligado Nacional (SIN). Suas atribuições relacionadas à operação centralizada podem ser agrupadas em cinco áreas principais[10], [11]:

- **Planejamento da Operação** – Estudos e análises operacionais de 5 anos a uma semana à frente da operação.
- **Programação da Operação (Pré-despacho)** – Atividades operacionais desenvolvidas dentro de um horizonte de uma semana até o dia que antecederá a operação propriamente dita.
- **Supervisão e Coordenação em tempo real (despacho)** – Atividades que vão desde a operação em tempo real até algumas horas à frente

- **Análise Estatística Pós-Operativa** – Atividades de análise dos resultados da operação, armazenando dados estatísticos para as demais etapas.
- **Contabilização e faturamento energético** - Medições de geração e consumo para as transações financeiras entre agentes do sistema elétrico

No que se refere às atividades de planejamento da operação e programação diária, o Operador Nacional do Sistema (ONS) utiliza uma cadeia de modelos desenvolvidos pelo Centro de Pesquisas de Energia Elétrica (CEPEL) [12]. A cadeia de planejamento possui três principais horizontes de tempo:

- Estudos de médio e longo prazo (estratégicos)
- Estudos de curto prazo (táticos)
- Programação Diária da operação (operacionais)

Os níveis estratégicos do planejamento da geração em sistemas se diferenciam quanto à sua complexidade e abordagem [12]. Estudos de médio e longo prazo devem lidar com incertezas relacionadas à demanda e à afluência de vazões, que em geral são baseadas em dados históricos e modelos probabilísticos, o que acarreta em um problema de característica mais abrangente.

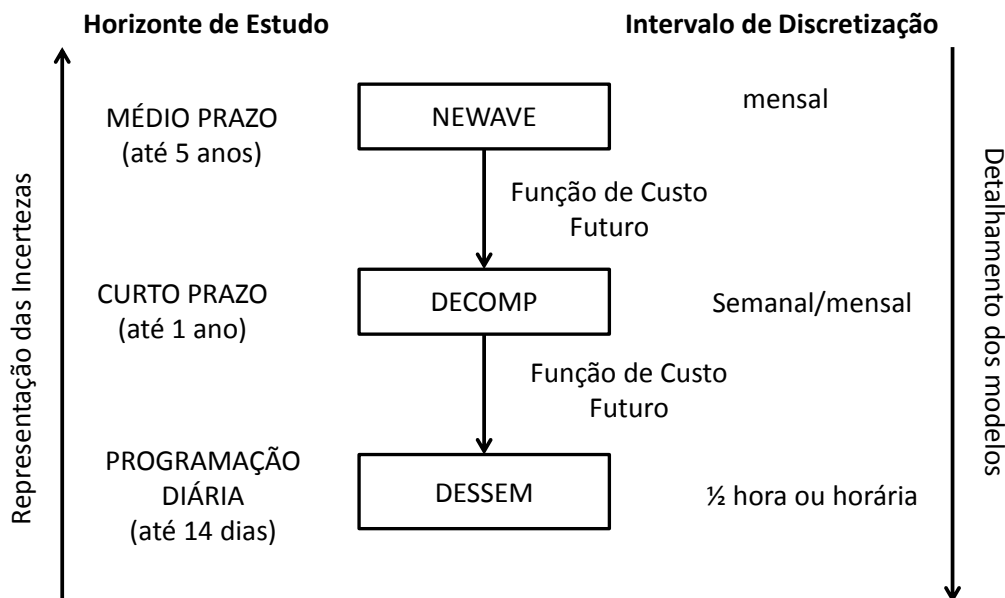


Figura 2.2 - Cadeia de modelos de Planejamento de operação do SIN, desenvolvidos pelo CEPEL. (Adaptado de [1])

Devido às incertezas, em geral, os modelos adotados possuem simplificações e uma visão mais geral do sistema, com simplificações na representação de usinas e do sistema elétrico. Em estudos de mais curto prazo a abordagem é determinística por possuir uma proximidade maior com a programação diária da operação. O acoplamento entre os modelos é feito através de funções de custo futuro, partindo do planejamento de longo e médio prazo até o planejamento de curto prazo. Esta função visa fornecer uma estimativa, a partir dos volumes dos reservatórios, dos custos esperados de geração térmica e déficit de energia ao longo de cada horizonte de planejamento.

2.2.2.1 Planejamento de longo e médio prazo

Os horizontes de planejamento de médio e longo prazo se tornam necessários devido a natureza do sistema elétrico brasileiro, que possui forte predominância hidráulica, necessitando de um planejamento estratégico para sua operação. No planejamento de longo prazo, tem-se em vista um horizonte de vários anos à frente, com discretização da ordem mensal.

Neste horizonte, os sistemas hidráulicos e térmicos são representados de forma agregada e o principal objetivo é estabelecer a proporção entre as gerações hidrelétricas e termelétricas, de modo a manter uma confiabilidade mínima de atuação. Utiliza-se uma modelagem mais simplificada do sistema, com reservatórios equivalentes das usinas hidrelétricas.

Os estudos de planejamento de longo e médio prazo determinam os níveis de geração hidrelétrica e térmica que minimizam o valor do custo de operação. Este custo corresponde ao custo variável de combustível das térmicas junto ao custo relacionado à penalização por déficit de energia. A principal ferramenta computacional utilizada no planejamento de médio e longo prazo é o NEWAVE [12], desenvolvida pelo CEPTEL.

No modelo NEWAVE [12] a decisão de quando utilizar os estoques de água dos reservatórios está ligada diretamente à incerteza quanto às afluências futuras, sendo adotada uma abordagem probabilística com base em dados históricos. Como o sistema brasileiro possui elevada quantidade de usinas hidrelétricas, a operação individual dos reservatórios e dos níveis de afluências frente a diversas possibilidades de cenário tornariam o problema intratável do ponto de vista computacional. Para isso, o modelo

do NEWAVE trabalha com reservatórios equivalentes, em subsistemas equivalentes de energia.

O planejamento de médio prazo é em geral considerado aquele que engloba meses até alguns anos à frente da operação. Os sistemas térmicos e hidráulicos são considerados individualmente, de forma a produzir políticas energéticas para a operação das usinas, a partir dos resultados da etapa de planejamento de longo prazo. Como saída, o planejamento de médio prazo fornece metas energéticas para o estudo de planejamento de curto prazo.

2.2.2.2 Planejamento de curto prazo

No planejamento de curto prazo, o horizonte é em geral em torno de meses, com discretização semanal no primeiro mês e mensal no restante do período. Neste estudo são considerados os vínculos hidráulicos entre usinas, tendo como resultados principais a evolução do nível dos reservatórios de cada usina e o valor da água no horizonte de planejamento.

O modelo de planejamento da operação de curto prazo e também utilizado em estudos de médio prazo é o DECOMP [12]. O objetivo básico do planejamento em curto prazo é determinar para cada estágio, da ordem de semanas, as metas de geração por usina, de forma a também minimizar o custo de operação. A disponibilidade de energia hidrelétrica será dada pelas etapas de planejamento de médio e longo prazos.

O modelo DECOMP é utilizado com diferentes graus de detalhamentos para representação do sistema, abrangendo períodos de estudos com horizontes distintos, em médio prazo, curto prazo e programação diária. Neste modelo passam a ser adotadas as restrições elétricas e hidráulicas especiais em cada unidade, o que permite determinar o nível de geração individual e o intercâmbio entre áreas.

2.2.2.3 Programação diária da operação

A programação diária de operação é a última etapa da cadeia de modelos de planejamento. Este estudo define as formas finais de uso das fontes geradoras assegurando o atendimento as diretrizes do planejamento da operação de curto prazo.

Os resultados obtidos no planejamento de curto prazo fornecem à operação em tempo real uma estimativa de despacho programado para cada intervalo de tempo.

A programação diária tem o objetivo de estabelecer os níveis de geração individualizada de cada usina hidrelétrica e térmica, intercâmbios entre áreas e atendimento a demanda do dia seguinte de operação, com horizonte diário e discretização horária. O modelo DESSEM vem sendo desenvolvido pelo CEPEL com o intuito de suprir essa necessidade e poder estabelecer custos marginais com base horária [12]. O objetivo principal deste modelo é o de definir uma programação ótima base para a operação hidrotérmica, com o objetivo principal de definir os custos marginais com característica horária. Para tal aplicação o modelo DESSEM considera simplificações do sistema hidrelétrico, como não adoção das curvas colinas das máquinas e representação simplificada dos reservatórios.

A partir dos estudos de curto prazo e de planejamento diário são definidas metas de geração por usinas, ou conjunto de usinas, definindo por exemplo os níveis de operação desejáveis para os reservatórios ao fim do dia. Partindo de tais metas estabelecidas, a distribuição ótima da geração entre máquinas em uma mesma usina ou de um conjunto de usinas se torna um problema de decisão local, ou seja, cada agente de geração deve definir a própria programação da geração de suas unidades.

Também no âmbito da operação diária, é de interesse das empresas que haja um melhor aproveitamento dos recursos energéticos. Por este motivo, torna-se importante um melhor estudo e desenvolvimento de métodos de otimização da geração, o que representa diminuição de custos e maximização dos lucros dos agentes de geração.

O problema da programação da operação energética diária possui abordagens diferentes, variando com o tipo de sistema estudado. O problema pode ser tratado a partir de um conjunto de usinas geradoras, ou de uma única unidade. As principais características que devem ser determinadas neste tipo de estudo são [1]:

- **Tipo de sistema:** O problema da operação diária pode ser aplicado a sistemas térmicos, hidrelétricos, ou sistemas hidrotérmicos.
- **Tipo de acoplamento:** O acoplamento pode ser estático ou dinâmico. O problema pode ser definido como de acoplamento estático quando se

desconsidera o efeito temporal das decisões. Já problemas de acoplamento dinâmico possuem uma interdependência entre decisões tomadas em instantes de tempo posteriores com decisões tomadas em intervalos de tempo anteriores.

- **Determinação da alocação de unidades geradoras:** Este tipo de estudo pode envolver a tomada de decisão do status (ligado/desligado) das unidades geradoras individualmente, ou assumi-la pré-definida.
- **Representação hidráulica das usinas:** A operação das usinas hidrelétricas pode ser feita somente na parte energética, ou tratar também a questão da operação dos reservatórios.
- **Consideração da rede elétrica:** A consideração da rede elétrica pode ser feita a partir de uma modelagem mais completa, de forma mais simples, ou pode-se decidir por não representar a mesma.

Este trabalho tem como objetivo contribuir com um modelo de otimização da operação da geração diária de usinas hidrelétricas em cascata, podendo ser utilizada pelas operadoras de energia para otimizar sua operação seguindo as curvas de carga pré-determinadas. A otimização tem como principal objetivo evitar desperdícios de recursos energéticos. A demanda do sistema ao longo do dia será considerada como dado de entrada e estimada pelas demais etapas de planejamento. Com o modelo DESSEM ainda não está em plena implementação, tal abordagem de atendimento à demanda ainda não vem sendo adotada, cabendo às próprias empresas de geração estimar sua demanda diária que atendam a outros fatores do planejamento.

No Capítulo 3 será dado um enfoque a apresentação matemática da modelagem de usinas hidrelétricas e apresentada a formulação do problema de otimização.

CAPÍTULO 3

FORMULAÇÃO MATEMÁTICA

3.1 Introdução

Este capítulo apresenta a formulação matemática da operação e produção de energia de usinas hidrelétricas em cascata. Serão apresentados os fatores considerados no cálculo da produção hidrelétrica, modelos das turbinas hidrelétricas, modelagem das perdas, restrições operativas e as equações utilizadas para representar a utilização de água nos reservatórios. Por fim será apresentada a formulação matemática para o problema de otimização.

Conforme apresentado no capítulo anterior, o objetivo fundamental do estudo de planejamento da operação é determinar o despacho de um conjunto de usinas, que atenda a uma demanda programada ou que possibilite a utilização controlada dos reservatórios dentro das margens de operação pré-definidas. O problema de planejamento de operação de usinas hidrelétricas em cascata em curto prazo é um problema complexo que necessita de grande detalhamento dos processos de geração e operação. Entre as variáveis do problema estão: níveis de geração, vazão turbinada,

afluência e volume dos reservatórios. O problema é de característica não linear e um problema sujeito a restrições de diferentes naturezas.

3.2 Modelagem de Unidades Hidrelétricas

Nesta seção serão apresentados os principais dados necessários para a representação do modelos de geração de usinas geradoras hidrelétricas. Entre os quais, a descrição de seus componentes, a determinação da função de geração hidrelétrica, a curva de eficiências das turbinas hidrelétricas e as condições de operação da geração destas usinas.

3.2.1 Descrição dos Componentes

A Figura 3.1 apresenta os principais componentes presentes em uma usina hidrelétrica.




Figura 3.1- Esquema simplificado dos elementos de uma usina hidrelétrica

O reservatório é a área onde se armazena a água que será turbinada para gerar energia. As unidades geradoras, situadas na casa de força, são as responsáveis por transformar a energia potencial da água em energia elétrica. A unidade geradora é composta pela turbina, pelo gerador e seus componentes auxiliares. A água a ser turbinada entra pelo canal de admissão, seguindo pelo conduto forçado até ser turbinada pela máquina e seguir pelo canal de fuga. A turbina transforma o potencial hidrelétrico em potência mecânica, e o gerador, acoplado ao eixo da turbina, realiza a transformação da energia mecânica em energia elétrica, que por sua vez é exportada à rede.

3.2.2 Formulação da Geração Hidrelétrica

O conceito básico da geração hidrelétrica é o de transformar a energia potencial da água armazenada no reservatório em energia mecânica nas turbinas e posteriormente energia elétrica nos geradores. A Figura 3.2 identifica as variáveis utilizadas para representar cada etapa do processo de produção de energia e as respectivas perdas no processo de geração de uma unidade hidrelétrica [2].




Figura 3.2 – Variáveis da etapa de produção de energia hidrelétrica.

As respectivas variáveis do processo são descritas abaixo:

- phd*: Potência hidráulica disponível, relacionada à energia potencial da água armazenada no reservatório, referente a uma queda bruta *hb*.
- pst*: Potência mecânica de saída da turbina
- peg*: Potência mecânica na entrada do gerador
- pg*: Potência elétrica de saída nos terminais do gerador
- pmt*: Perdas mecânicas no eixo da turbina
- pgg*: Perdas globais no gerador

A potência disponível em uma unidade hidrelétrica está associada fundamentalmente à energia potencial da água armazenada. A expressão matemática para a determinação da potência bruta associada a uma unidade hidrelétrica pode ser obtida pela taxa de variação de volume (vazão) e da altura bruta, na seguinte relação:

$$phd = \rho . g . hb . q \quad (3.1)$$

Sendo:

phd: A potência hidrelétrica disponível (W)

ρ :	Peso específico da água (1.000 kg/m ³)	(kg/m ³)
g :	Aceleração da gravidade (9,81 m/s ²)	(m ³ /s)
hb :	A altura de queda d'água bruta, definida como a diferença entre os níveis do reservatório a jusante e do canal de fuga a montante.	(m)
q :	Vazão turbinada	(m ³ /s)

A Equação (3.1) relaciona a potência hidrelétrica disponível, phd , com a vazão turbinada q e a altura da queda d'água bruta hb . A queda bruta (hb) é calculada como a diferença entre os níveis da cota do reservatório a montante (fc_m) e da cota do reservatório a jusante (fc_j) e definida como:

$$hb = fc_m - fc_j \quad (3.2)$$

A cota a montante de uma usina (fc_m) pode ser determinada a partir do volume de seu reservatório e dada pelo seguinte polinômio [13]:

$$fc_m = a_0 + a_1 v_{rt} + a_2 v_{rt}^2 + a_3 v_{rt}^3 + a_4 v_{rt}^4 \quad (3.3)$$

Sendo:

a_i	Coeficiente do polinômio da cota a montante do reservatório	(-)
v_r	Volume do reservatório r no instante de tempo t	(m ³)

A cota a jusante (fc_j) é calculada em função da vazão turbinada e vertida por cada usina e também representada por um polinômio:

$$fc_j = b_0 + b_1(Q + s) + b_2(Q + s)^2 + b_3(Q + s)^3 + b_4(Q + s)^4 \quad (3.4)$$

Sendo:

b_i :	Coeficiente do polinômio da cota a jusante do reservatório	
Q :	Vazão total turbinada pelas unidades comuns ao conduto forçado	(m ³ /s)
s :	Vazão total vertida no reservatório	(m ³ /s)

Nos casos em que o vertedouro se encontra distante do canal de fuga é comum também se desconsiderar o termo equivalente à vazão vertida, s .

A transformação da potência hidráulica para potência mecânica é realizada pela turbina. A potência de saída da turbina será dada por:

$$pst = G \cdot \eta \cdot h \cdot q \quad (3.5)$$

Sendo:

G :	Constante igual a $\rho \cdot g = 9,81 \cdot 10^{-3}$	$(kg \cdot m^2 \cdot s^{-2})$
p_{st} :	Potência de saída da turbina	(MW)
η :	A eficiência da turbina	$(-)$
h :	A queda de água líquida	(m)
q :	Vazão turbinada na unidade	(m^3/s)

3.2.3 Perdas Hidráulicas

Na condução da água até a turbina, através do sistema de dutos, ocorre fricção no sistema de adução que acarreta em perdas hidráulicas no processo de transformação de energia. Portanto, nem todo o potencial de queda bruta de água fica diretamente disponível para conversão em potência mecânica na turbina. Estas perdas hidráulicas são expressas em função de altura de queda d'água.

Sendo assim, a altura líquida (h) será definida a partir da queda bruta, descontados os fatores de atenuação devido às perdas hidráulicas (hls) e devido ao atrito no conduto forçado (hlp), conforme apresentado a seguir:

$$h = hb - hlp - hls \quad (3.6)$$

Em que:

$$hls = ks q^2 \quad (3.7)$$

$$hlp = kp q^2 + kpu Q^2 \quad (3.8)$$

Sendo:

h :	Queda d'água líquida	(m)
hls :	Fator de atenuação da queda bruta devido às perdas hidráulicas	(m)
hlp :	Fator de atenuação da queda bruta devido ao atrito da água no conduto forçado	(m)
ks :	Constante de proporcionalidade para as perdas hidráulicas	(s^2/m^5)
kp :	Constante de proporcionalidade para as perdas por atrito nos condutos forçados individualizados	(s^2/m^5)
kpu :	Constante de proporcionalidade para as perdas por atrito no conduto forçado comum a todas as turbinas do reservatório	(s^2/m^5)

3.2.4 Perdas Mecânicas e Elétricas

A potência de saída da turbina não é totalmente entregue ao gerador, devido à presença de perdas mecânicas. Consideradas as perdas mecânicas da turbina (p_{mt}), a potência entregue ao gerador (p_{eg}) será dada por:

$$p_{eg} = p_{st} - p_{mt} \quad (3.9)$$

Sendo:

p_{eg} : Potência entregue ao gerador

p_{st} : Potência de saída da turbina (MW)

p_{mt} : Perdas mecânicas na turbina (MW)

A potência elétrica gerada será dada pela diferença entre a potência entregue ao gerador e as perdas globais no gerador. A potência elétrica gerada será igual a:

$$p_g = p_{eg} - p_{gg} \quad (3.10)$$

Sendo:

p_g : Potência elétrica gerada (MW)

p_{gg} : Perdas globais no gerador (MW)

3.2.5 Curvas de Eficiência das Turbinas

Conforme visto anteriormente, a potência de saída de uma unidade geradora depende basicamente da altura da queda de água líquida, da vazão turbinada pela unidade e da eficiência da turbina. A eficiência da turbina representa a eficácia com que a potência disponível na água que flui através da turbina é transferida para o eixo do rotor. As turbinas possuem curvas de rendimento próprias e de característica não linear. O rendimento da turbina depende da vazão turbinada e da altura de queda líquida. A equação característica da eficiência de uma turbina hidráulica é dada pela seguinte equação:

$$\eta = c_0 + c_1q + c_2h + c_3qh + c_4q^2 + c_5h^2 \quad (3.11)$$

Sendo:

c_i : Os coeficientes da curva de eficiência

A equação anterior define um conjunto de curvas conhecidas como curvas colina. A Figura 3.3 mostra a característica de tal conjunto de curvas.




Figura 3.3 – Curva colina de uma turbina hidráulica.

Em casos práticos os valores característicos do rendimento máximo para grandes turbinas ficam na faixa de 88 a 96% [14]. Em geral os fabricantes fornecem um conjunto de dados (η, p_{st}, h) a partir dos quais é possível obter o polinômio de eficiência da turbina em função da altura líquida e da vazão utilizando técnicas de regressão.

3.2.6 Restrições de Operação das Turbinas

As turbinas de geração hidrelétrica atuam com zonas proibitivas de geração, com finalidade de evitar o efeito de vibrações e evitar a diminuição do tempo de vida útil da máquina. A Figura 3.4 mostra um exemplo das faixas de potência característica das turbinas para diferentes vazões e alturas e também as faixas de potência proibidas para operação em razão dos efeitos anteriormente citados.




Figura 3.4 – Regiões de operação das turbinas hidrelétricas, para diferentes faixas de potência, com indicação das zonas proibitivas de operação.

As faixas de potência permissíveis para atuação fazem também com que a potência de saída da turbina seja limitada na faixa

$$pgmin_{jr} \leq pg_{jrt} \leq pgmax_{jr} \quad (3.12)$$

Sendo:

$pgmin$: Potência mínima disponível para a unidade j da usina r

$pgmax$: Potência máxima disponível para a unidade j da usina r

pg_{jrt} : Potência de saída do gerador, unidade j usina r .

As turbinas possuem capacidade de turbinagem limitada, ou seja, limites quanto às vazões máximas e mínimas que as mesmas podem turbinar. Em cada unidade geradora, a vazão máxima e mínima pode ser definida em função da respectiva altura líquida, conforme se segue:

$$q_{max} = d_0 + d_1h + d_2h + d_3h^2 \quad (3.13)$$

$$q_{min} = e_0 + e_1h + e_2h + e_3h^2 \quad (3.14)$$

Sendo:

$d_0, \dots, d_3, e_0, \dots, e_3$: coeficientes de vazão máxima e mínima.

Portanto, a capacidade de turbinagem das unidades geradoras é definida por:

$$qmin_{jr} \leq q_{jrt} \leq qmax_{jr} \quad (3.15)$$

Sendo:

q_{jrt} : Vazão turbinada pela unidade j na usina r .

$qmin_{jr}$: Capacidade de turbinagem mínima da unidade j e usina r .

$qmax_{jr}$: Capacidade de turbinagem máxima da unidade j e usina r .

3.3 Operação do Reservatório de Usinas Hidrelétricas

Em estudos de planejamento de sistemas hidrelétricos, o problema de despacho da geração deve ser analisado conjuntamente com a operação do nível dos reservatórios de cada usina. A operação dos reservatórios de um conjunto de usinas trata de determinar de que forma a água será utilizada, em conjunto, de forma a alcançar um objetivo em comum e não violar condições de operação pré-determinadas.

Em um sistema de usinas em cascata, a operação dos reservatórios é crítica, visto que a redução do uso da água em uma usina a montante pode acarretar em falta de água nas usinas a jusante, e um uso excessivo da água em uma usina a montante pode acarretar em vertimento nos demais reservatórios. A complexidade da operação depende da complexidade hidrelétrica do sistema e do número de usinas consideradas.

Pode-se citar duas principais características do problema de operação dos reservatórios de usinas hidrelétricas em cascata, que são:

- **Acoplamento espacial:** A operação dos reservatórios é de característica acoplada no espaço, ou seja, decisões tomadas em um ponto a montante afetam diretamente os pontos a jusante. Usos desregulados da água acarretam em alteração dos níveis dos reservatórios em diferentes pontos do sistema, o que pode acarretar em déficit energético, ou simplesmente em uma operação ineficaz em termos de utilização da água.
- **Acoplamento temporal:** A operação dos reservatórios é acoplada no tempo, pois decisões tomadas no presente afetam decisões futuras. Um uso excessivo de água pode acarretar em um déficit futuro, o que conseqüentemente acarreta um

déficit energético. Um uso conservador da água pode acarretar em vertimento da água nos intervalos de tempos futuros, o que também não é uma condição ideal, pois se trata do desperdício de um recurso energético.




Figura 3.5 – Esquema representativo de usinas hidrelétricas em cascata.

A principal relação a ser observada na operação dos reservatórios de usinas hidrelétricas em cascata é a conservação de massa, ou conservação de água. O nível de um reservatório é calculado a partir de seu valor inicial mais o somatório das vazões afluentes a ele, mais a vazão turbinada e vazão vertida por todas as usinas a montante menos a vazão turbinada e vertida pela própria usina. Sendo assim, a consideração da equação de conservação de massa no problema é feita através da adoção da seguinte equação:

$$v_{rt} = v_{r,t-1} + C \cdot y_{rt} - c_1 \cdot \left[Q_{rt} + s_{rt} - \sum_{m \in R_{up}^j} (Q_{m,t-\tau_{mr}} + s_{m,t-\tau_{mr}}) \right] \quad (3.16)$$

Sendo:

- v_{rt} : Volume do reservatório r no instante de tempo t (m^3)
- y_{rt} : Vazão aflente total ao reservatório r no instante de tempo t (m)
- Q_{rt} : Vazão turbinada total pela usina de reservatório r no instante de tempo t (m^3/s)
- s_{rt} : Vazão vertida total pela usina de reservatório r no instante de tempo t (m^3/s)
- c_1 : Constante de proporcionalidade entre vazão e volume, relacionada com a discretização Δt utilizada. Ex: Se $\Delta t = 1h$, então $c_1 = 3600 s$. (s)
- τ_{mr} : Tempo de deslocamento entre as águas do reservatório r e (h)

reservatório m

R_{up}^j : Conjunto de reservatórios a montante do reservatório j (–)

3.4 Formulação do Problema

Nesta seção será formulado o problema de programação da geração de unidades geradoras em usinas hidrelétricas em cascata como um problema de otimização multiestágio.

Os problemas de otimização, de forma genérica, se caracterizam por uma função objetivo, a qual se deseja minimizar ou maximizar, e um conjunto de restrições, na seguinte característica:

Função Objetivo:

$$\text{Min } f(x) \tag{3.17}$$

Sujeito às restrições:

$$\begin{aligned} g(x) &\leq 0 \\ h(x) &= 0 \end{aligned} \tag{3.18}$$

Sendo:

- $f(x)$: Função Objetivo
- $g(x) = 0$: Restrição de igualdade
- $g(x) \leq 0$: Restrição de desigualdade

O objetivo do problema de otimização deste trabalho será calcular o despacho ótimo (a nível de unidade geradora) de um conjunto de usinas de forma a atender uma demanda pré-determinada utilizando a menor quantidade de recursos hídricos disponível. As restrições deste problema englobam o conjunto de restrições elétricas, hidráulicas e operativas do sistema.

O problema aqui apresentado será tratado a partir de duas parcelas, dois subproblemas concomitantes: problema de despacho energético ótimo e problema de alocação de unidades geradoras.

O problema de alocação de unidades é um problema que visa determinar quantas ou quais unidades geradoras de quais usinas devem ser despachadas, tratando-se basicamente de um problema de característica inteira (número de unidades ou índice de quais unidades serão despachadas em cada intervalo de tempo).

O problema de despacho econômico ótimo visa determinar, a partir da estimativa do despacho ou não de cada unidade ao longo do dia, qual deve ser a potência despachada, em cada intervalo de tempo, de forma a reduzir a quantidade total de água utilizada. Trata-se em geral de um problema com variáveis contínuas.

Desta forma, em sua solução mais detalhada, o problema não pode ser tratado de forma separada ou subdividido. Uma abordagem que pese concomitantemente a solução dos dois subproblemas foi abordada.

3.4.1 Despacho Energético Ótimo

O objetivo básico do despacho energético ótimo é reduzir a quantidade total de água turbinada e vertida pelo conjunto de usinas no tempo de planejamento considerado.

Matematicamente, a função objetivo do problema pode ser definida como:

$$\text{Min} \sum_{i=1}^N \sum_{t=0}^T Q_{i,t} + s_{i,t} \quad (3.19)$$

Sendo:

$Q_{i,t}$:	Vazão turbinada pela usina i no intervalo de tempo t	(m^3/s)
$s_{i,t}$:	Vazão vertida pela usina i no intervalo de tempo t	(m^3/s)
N :	Número de usinas	(-)
T :	Número total de intervalos de tempo	(-)

A variável t representa o índice do intervalo de tempo e a variável i representa o índice da usina considerada. A equação acima representa o somatório de toda vazão turbinada e toda vazão vertida por cada uma das N usinas em cascata nos T intervalos de tempo considerados.

3.4.2 Alocação de Unidades

O problema de alocação de unidades visa determinar em quais intervalos de tempo as unidades geradoras estarão ligadas ao longo do dia.

Para que a solução ótima não seja feita por condições de operação em que hajam repentinos ligamentos e desligamentos de máquinas é adotado um valor de peso de transição de estado a cada máquina. Nesta condição, a função objetivo adotada será minimizar o peso de transição adotado.

A parcela da função objetivo que se refere a este condição é dada por:

$$\text{Min} \sum_{r=1}^R \sum_{j=1}^{n_t} \sum_{t=0}^T \sigma_{1jr} \cdot [u_{jrt}(1 - u_{jrt-1})] + \sigma_{2jr} [u_{ij,t-1}(1 - u_{jrt})] \quad (3.20)$$

Sendo:

- σ_{1jr} : Penalidade associada ao custo de partida das unidades (–)
 σ_{2jr} : Penalidade associada ao custo de desligamento das unidades (–)
 u_{ijt} : Estado (ligado/desligado) da unidade j da usina r no instante de tempo t (0/1)

3.4.3 Otimização da Geração Diária de um Conjunto de Usinas Hidrelétricas em Cascata

O problema de otimização da operação diária de usinas hidrelétricas em cascata é dado pela combinação dos dois subproblemas: despacho ótimo de energia e alocação de unidades. Os dois subproblemas são tratados simultaneamente, dando origem a um único problema. O problema de otimização tratado neste trabalho será de minimização e sua função objetivo será definida como:

$$f(x) = \left[\sum_{t=1}^T \sum_{r=1}^R Q_{rt} + s_{rt} + \sum_{j=1}^{nrt} \sigma_{1jr} \cdot [u_{jrt}(1 - u_{jrt-1})] + \sigma_{2jr} [u_{ij,t-1}(1 - u_{jrt})] \right] \quad (3.21)$$

O conjunto de restrições deste problema é dado pelo conjunto de restrições hidráulicas, elétricas e operativas do sistema hidrelétrico em cascata. Matematicamente estes problemas são formulados conforme apresentado a seguir:

Restrição de atendimento a demanda:

$$\sum_{j=1}^{nr} \sum_{t=1}^T pg_{jrt} \geq L_t \quad (3.22)$$

Balço de massa entre reservat3rios:

$$v_{rt} = v_{r,t-1} + c_1 \cdot y_{rt} - c_1 \cdot \left[Q_{rt} + s_{rt} - \sum_{m \in R_{up}^j} (Q_{m,t-\tau_{mr}} + s_{m,t-\tau_{mr}}) \right] \quad (3.23)$$

Limites m3nimos e m3ximos dos reservat3rios:

$$v_r^{min} \leq v_{rt} \leq v_r^{max} \quad (3.24)$$

Limites operativos de vaz3o:

$$q_{jrt}^{min}(\dots) \leq q_{jrt} \leq q_{jrt}^{max}(\dots) \quad (3.25)$$

Limite de pot3ncia por unidade geradora:

$$pg_{jrt}^{min} \cdot u_{jrt} \leq pg_{jrt} \cdot u_{jrt} \leq pg_{jrt}^{max} \cdot u_{jrt} \quad (3.26)$$

Limite de vaz3o defluente m3xima/m3nima:

$$U_r^{min} \leq U_{rt} \leq U_r^{max} \quad (3.27)$$

Varia3o m3xima de vaz3o afluyente por intervalo de tempo:

$$|(U_{r,t}) - (U_{r,t-1})| \leq d_r^{max} \quad (3.28)$$

Restri3o de reserva girante m3nima dispon3vel:

$$\sum_{r=1}^R \sum_{j=1}^{n_{rt}} pg_{jrt}^{max} - pg_{jrt} \geq g_t \quad (3.29)$$

Sendo:

T :	N3mero total de est3gios	(-)
R :	N3mero total de reservat3rios	(-)
n_{rt} :	N3mero dispon3vel de unidades na usina de reservat3rio r no instante de tempo t	(-)
c_1 :	Constante de proporcionalidade entre vaz3o e volume, relacionado com a discretiza3o Δt utilizada. Ex: Se $\Delta t = 1h$, ent3o $C = 3600 s$.	(s)
τ_{mr} :	Tempo de deslocamento entre as 3guas do reservat3rio r e reservat3rio m	(h)
R_{up}^j :	Conjunto de reservat3rios a montante do reservat3rio j	(-)
Q_{rt} :	Vaz3o turbinada total na usina de reservat3rio r no instante de tempo t	(m^3/s)
s_{rt} :	Vaz3o vertida no reservat3rio r no instante de tempo t	(m^3/s)

σ_{1jrt} :	Custo de partida da unidade j do reservatório r no intervalo de tempo t	(m^3/s)
σ_{2jrt} :	Custo de parada da unidade j do reservatório r no intervalo de tempo t	(m^3/s)
u_{jrt} :	Indicação de se a unidade j , reservatório r no instante de tempo t está ligada ou desligada. [0=desligado 1=ligado]	$(-)$
pg_{jrt} :	Potência gerada pela unidade j , do reservatório r no instante de tempo t	(MW)
pg_{jr}^{max} :	Capacidade máxima de potência da unidade geradora j da usina r	(MW)
pg_{jr}^{min} :	Capacidade mínima de potência da unidade geradora j da usina r	(MW)
L_t :	Potência demandada pelo sistema no intervalo de tempo t .	(MW)
v_{rt} :	Volume do reservatório r no instante de tempo t	(m^3)
v_r^{min} :	Volume mínimo do reservatório r no instante de tempo t	(m^3)
v_r^{max} :	Volume máximo do reservatório r no instante de tempo t	(m^3)
q_{jrt} :	Vazão turbinada pela unidade j da usina de reservatório r no instante de tempo t	(m^3/s)
q_{jrt}^{min} :	Vazão turbinada mínima da unidade j da usina de reservatório r para o intervalo de tempo t	(m^3/s)
q_{jrt}^{max} :	Vazão turbinada máxima da unidade j da usina de reservatório r para o intervalo de tempo t	(m^3/s)
U_{rt} :	Vazão defluente da usina r no instante de tempo t	(m^3/s)
U_r^{min} :	Vazão defluente mínima	(m^3/s)
U_r^{max} :	Vazão defluente máxima	(m^3/s)
d_r^{max} :	Limite máximo de variação de vazão defluente na usina r entre dois intervalos de tempo consecutivos	(m^3/s)
g_t :	Reserva girante necessária no instante de tempo t	(MW)

A função objetivo pondera os custos de utilização de água juntamente com os custos de operação de partida e desligamento de unidade em uma mesma função objetivo.

As restrições do problema englobam todas as restrições físicas e operativas consideradas para este sistema, englobando unidades geradoras, reservatórios e sistema elétrico. O atendimento a todas as restrições diz se uma solução, do ponto de vista operacional, é viável ou não.

A restrição de atendimento à demanda foi adotada de forma a suprir minimamente a carga estipulada para o conjunto de usinas. A demanda ao longo do dia pode ser interpretada como dado de entrada, vindo dos modelos de planejamento da programação diária, parte do planejamento centralizado realizado pelo ONS.

Atualmente a curva de demanda ao longo do dia é estipulada pelas próprias usinas geradoras, que determinam seu próprio planejamento, sendo o mesmo enviado ao ONS. Com a futura implementação definitiva do modelo DESSEM, espera-se que a curva de geração seja fornecida pelo planejamento centralizado, a partir da qual pode ser seguida a lógica de programação e otimização implementada neste trabalho.

Outras restrições podem também ser adotadas, entre as quais podemos citar a de limite de tempo mínimo e máximo para a mudança de estados das máquinas. Desta forma, impede-se um número elevado de ligamentos e desligamentos de unidades em curtos intervalos de tempo, comportamento indesejado na operação. Neste trabalho foi decidido não representar tal restrição, sendo avaliado que o custo associado às partidas e as paradas limita de forma adequada a transição de estados das máquinas.

CAPÍTULO 4

METAHEURÍSTICAS

4.1 Introdução

Este capítulo apresenta a definição de metaheurísticas, métodos de otimização utilizados em problemas dos mais variados ramos. São também apresentados três diferentes métodos metaheurísticos de característica populacional, sendo estes: Otimização por Enxame de Partículas, Algoritmo Genético e Algoritmo de Evolução Diferencial. Ao longo do capítulo são demonstradas e definidas diferentes variações destes métodos, que são aplicados ao problema de otimização presente nesta dissertação.

Metaheurísticas são técnicas de otimização que criam procedimentos de busca baseados em escolhas aleatórias e conhecimento histórico dos resultados precedentes, sendo capazes de realizar uma varredura eficiente pelo espaço de soluções. São em geral aplicadas em problemas cuja solução é de difícil solução (não há uma estimativa inicial bem definida) ou sobre os quais não se tem conhecimento sobre algoritmos eficientes de solução.

Métodos metaheurísticos guiam o processo de busca de soluções ótimas ou subótimas, explorando o espaço de busca de forma a fugir de soluções presas em mínimos locais e regiões confinadas. A eficiência dos métodos metaheurísticos está diretamente ligada à estratégia do processo de exploração, sendo em geral aplicável a problemas de diferentes características. As técnicas utilizadas podem variar de técnicas de menor até maior complexidade e se diferenciam pelo mecanismo de exploração adotado. A abordagem genérica dos métodos permite a solução de problemas de diferentes ramos do conhecimento através de rotinas de solução idênticas.

A natureza da busca das diferentes metaheurísticas depende amplamente da filosofia de solução de cada método aplicado. Conforme será tratado nas próximas seções, os métodos podem envolver recombinação entre soluções já existentes assim como adotar padrões de busca a partir dos resultados previamente encontrados. Os métodos podem ter características de base populacional ou de solução única, diferenciando-se na quantidade de soluções que são avaliadas simultaneamente. Métodos de característica populacional possuem a vantagem da possibilidade de paralelização do processo de solução, permitindo que diferentes soluções simultâneas sejam avaliadas o que facilita o tempo de processamento.

Neste trabalho serão tratados três diferentes métodos populacionais de busca e suas variações: Algoritmo de Otimização por Enxame de Partículas (PSO), Algoritmo Genético (AG) e Algoritmo de Evolução Diferencial (DE).

Os métodos metaheurísticos estudados neste trabalho possuem as seguintes características em comum:

- Característica populacional: Uma quantidade de soluções é testada simultaneamente a cada iteração.
- Característica estocástica: Critérios aleatórios são adotados durante o processo de busca. Diferentes soluções finais podem ser obtidas a partir de soluções iniciais idênticas.
- Algoritmos iterativos: Soluções ótimas são encontradas após um número determinado de iterações, partindo de soluções iniciais. A complexidade do problema em geral aumenta o número de iterações necessárias e consequentemente o tempo computacional.

4.2 Otimização por Enxame de Partículas

O método de Otimização por Enxame de Partículas (PSO – *Particle Swarm Optimization*) é uma técnica de otimização inspirada no comportamento social observado em populações de pássaros e de peixes. O método foi desenvolvido em 1995 por Eberhart e Kennedy e é um método de busca de soluções ótimas com base populacional.

O método se baseia em um conjunto inicial de soluções, denominadas partículas, que percorrem um espaço de busca com o objetivo de encontrar a melhor solução, ou posição entre elas. Ao conjunto de partículas dá-se o nome de enxame. Cada partícula do enxame possui uma posição e uma velocidade em um plano n dimensional, sendo n o número de dimensões do problema.

A exploração do espaço de busca feita por uma partícula visa seguir as melhores soluções já encontradas tanto pela própria partícula quanto pela sua vizinhança, permitindo varrer o espaço de busca e encontrar novas soluções de melhor avaliação. A exploração é feita atualizando-se as posições e velocidades das partículas a cada iteração. O processo é repetido por um número definido de iterações ou até que um critério de convergência definido seja alcançado. A Figura 4.1 mostra a posição e a velocidade de uma partícula em uma dada iteração do método.




Figura 4.1 – Enxame de partículas com as respectivas posições e velocidades de uma dada iteração, em um espaço de busca bidimensional.

O sucesso da busca de uma posição ótima por uma partícula depende não somente do desempenho da partícula individualmente, como também da informação compartilhada com o enxame. A esta inteligência conjunta do enxame atribuiu-se o conceito de “*Swarm Intelligence*” ou Inteligência de Enxame.

A utilização do PSO para resolver problemas multidimensionais complexos tem crescido expressivamente devido a sua simplicidade e fácil aplicabilidade. O método do PSO foi desenvolvido inicialmente para representação de problemas em um espaço de busca contínuo, porém há também abordagens que tratam o espaço de busca como uma representação discreta. Nas próximas seções serão mostrados os algoritmos respectivos a estas duas abordagens.

4.2.1 Algoritmo PSO Padrão

A formulação para a velocidade e a posição de cada partícula em cada iteração é feita da seguinte forma:

$$\vec{v}(t) = \omega \vec{v}(t-1) + \varphi_1 (\vec{P}_i - \vec{x}(t-1)) + \varphi_2 (\vec{P}_g - \vec{x}(t-1)) \quad (4.1)$$

$$\vec{x}(t) = \vec{x}(t-1) + \vec{v}(t) \quad (4.2)$$

Sendo:

$\vec{v}(t)$: A velocidade da partícula

$\vec{x}(t)$: A posição da partícula

φ_1 : Número aleatório de distribuição uniforme no intervalo $[0, \varphi_{1max}]$

φ_2 : Número aleatório de distribuição uniforme no intervalo $[0, \varphi_{2max}]$

ω : Coeficiente de inércia, decaimento da velocidade $[0,1]$

\vec{P}_i : A melhor posição histórica do indivíduo

\vec{P}_g : A melhor posição histórica de toda vizinhança

Em um problema de n variáveis, as variáveis $\vec{x}(t)$ e $\vec{v}(t)$ correspondem respectivamente à posição e a velocidade da partícula no espaço n -dimensional em um passo de simulação t . A cada uma das iterações, a velocidade da partícula é atualizada em função de \vec{P}_i e \vec{P}_g que representam respectivamente a melhor posição já visitada pela própria partícula e a melhor solução já avaliada pela vizinhança da mesma. A

velocidade é influenciada também por um fator de inércia, relativo à velocidade da partícula no instante anterior. Por fim, depois de calculada a velocidade de cada partícula da população atualiza-se a posição das mesmas e segue-se para a iteração seguinte, onde o processo é repetido.

Os coeficientes φ_1 e φ_2 correspondem respectivamente aos coeficientes cognitivo e social. O coeficiente cognitivo envolve informações históricas da própria partícula, enquanto o coeficiente social envolve informações históricas da vizinhança da mesma. Os dois coeficientes determinam o peso com que as melhores posições já visitadas interferirão no cálculo da velocidade.

A formulação inicial proposta em [15] se diferencia da formulação aqui adotada, pois não inclui o coeficiente de inércia, que foi proposto posteriormente [16]. Esta é a formulação mais aceita hoje em dia e mais adotada na representação do método PSO.

O papel da adoção do coeficiente de inércia é controlar o impacto da velocidade nos instantes anteriores sobre a velocidade atual. Um grande peso inercial facilita a exploração global enquanto um peso inercial pequeno facilita a exploração local. Uma das abordagens propostas para o coeficiente de inércia é adotá-lo como linearmente decrescente com o número de iterações, conforme apresentado a seguir[4]:

$$\omega(i) = \omega_{max} - \left(\frac{\omega_{max} - \omega_{min}}{N_{iter}} \right) * i \quad (4.3)$$

Sendo:

- i : Iteração do método
- N_{iter} : Número total de iterações
- ω_{max} : Coeficiente de inércia máximo
- ω_{min} : Coeficiente de inércia mínimo

Além da adoção do coeficiente de inércia, a velocidade pode também ser controlada da seguinte forma:

$$\begin{aligned} & \text{se } v < v_{min} \text{ então } v = v_{min} \\ & \text{se } v > v_{max} \text{ então } v = v_{max} \end{aligned} \quad (4.4)$$

Recomendações para a adoção dos parâmetros aqui listados podem ser amplamente observadas em [17] e [18].

4.2.2 Algoritmo PSO com Representação Binária

O método tratado anteriormente é aplicado a problemas com variáveis reais. Frente à possibilidade de utilização deste método em problemas de característica inteira e binária, é apresentado em [18] um método de Otimização por Enxame de Partículas de característica binária, que trata o espaço de busca de maneira discreta. Este método utiliza uma consideração probabilística na determinação da posição de cada partícula i e em cada dimensão d do problema. O algoritmo proposto é estruturado da seguinte forma por:

$$\vec{v}(t) = \omega \vec{v}(t-1) + \varphi_1 (\vec{P}_i - \vec{x}(t-1)) + \varphi_2 (\vec{P}_g - \vec{x}(t-1)) \quad (4.5)$$

$$s_{id}(v_{id}(t)) = \frac{1}{1 + \exp(-v_{id}(t))} \quad (4.6)$$

$$\begin{aligned} \text{se } \rho < s(v_{id}(t)) \text{ então } x_{id}(t) &= 1 \\ \text{caso contrário } x_{id}(t) &= 0 \end{aligned} \quad (4.7)$$

Sendo:

- i : Índice do indivíduo
- d : Índice da dimensão da partícula
- v_{id} : A velocidade da partícula
- x_{id} : Posição binária da partícula [0 ou 1]
- φ_1 : Número aleatório de distribuição uniforme no intervalo $[0, \varphi_{1max}]$
- φ_2 : Número aleatório de distribuição uniforme no intervalo $[0, \varphi_{2max}]$
- ω : Coeficiente de inércia, decaimento da velocidade $[0,1]$
- \vec{P}_i : A melhor posição histórica do indivíduo
- \vec{P}_g : A melhor posição histórica de toda vizinhança
- ρ_{id} : Número aleatório de distribuição uniforme no intervalo $[0,1]$
- $s(v_{id})$: Função Sigmoide, responsável pelo cálculo da probabilidade da partícula mover-se ou não na dada direção.




Figura 4.2 – Função sigmoide no intervalo [-8 , 8]

A diferenciação do método binário para o método com variáveis reais é a consideração da função Sigmoide, $s(v_{id})$, que de forma probabilística define a posição binária de cada dimensão da partícula. Enquanto as velocidades são calculadas como números reais, as posições possíveis para cada partícula em cada dimensão só poderão ter valores 0 ou 1. A característica da função Sigmoide é apresentada na Figura 4.2.

4.2.3 Topologia de Vizinhança para o PSO

Uma das importantes características do método PSO é a definição da topologia de sua vizinhança. Cada partícula é um membro de uma vizinhança social e sofre influência pela atuação de seus vizinhos. As partículas que percorrem o espaço de busca do método são afetadas pelo melhor ponto encontrado por seus vizinhos. Diferentes topologias já foram propostas e estudadas [19], havendo uma infinidade de possibilidades de definição de vizinhança. Sem a interação entre a vizinhança as partículas seriam reduzidas a um grupo de partículas isoladas com capacidades de busca limitadas.

Sendo a vizinhança um canal de atração entre as melhores posições das partículas é possível interpretar que um canal denso de comunicação com muitas partículas possibilita a intensificação da busca ao redor das melhores posições já encontradas. Apesar dessa rápida difusão de boas soluções encontradas possibilitar uma rápida convergência, também possibilita uma convergência prematura para posições de mínimos locais, o que não é desejável para o método. Soluções com vizinhança menos densas possibilitam uma convergência mais suave, permitindo uma maior diversidade e

capacidade de exploração, porém sofrem de uma capacidade de convergência mais lenta e por vezes ineficaz.

As topologias de vizinhança se diferenciam basicamente pela quantidade de partículas que cada partícula está conectada e pela característica de essa conexão se manter constante ou não durante a simulação. Nas versões primordiais do método PSO o mais comum seria adotar uma vizinhança do tipo Global, onde todas as partículas estão conectadas com as demais partículas vizinhas, sendo uma vizinhança invariável no tempo. Esta configuração é chamada de Topologia Global.

A tendência da solução utilizando a topologia global convergir rapidamente para soluções mais bem avaliadas acaba levando o método a ficar preso em pontos de mínimos locais. Esta característica dá origem à busca pela adoção de topologias de característica local. Nestas topologias cada partícula está conectada somente a um número k de outras partículas, fazendo com que as mesmas a troca de informações entre a população seja limitada.

As topologias locais mais comuns são a topologia em anel e topologia em roda. Na primeira as partículas interagem com as k partículas mais próximas, na segunda toda informação é filtrada por um único indivíduo central. A Figura 4.3 apresenta algumas topologias possíveis para o PSO.




Figura 4.3 – Topologia em anel, roda e vizinhança global.

4.2.4 PSO Unificado (UPSO)

O método do PSO unificado foi proposto em 2004 [20] como uma variação do PSO de maneira a intensificar a capacidade de exploração e a diversidade na busca pela solução ótima. Este método engloba duas diferentes topologias de vizinhança simultaneamente. A velocidade da partícula terá componentes influenciadas pela topologia de vizinhança global e por uma topologia de vizinhança local. A velocidade e posição de cada indivíduo serão atualizadas da seguinte forma:

$$\vec{v}_1(t) = \omega \vec{v}(t-1) + \varphi_1 (\vec{P}_i - \vec{x}(t-1)) + \varphi_2 (\vec{P}_G - \vec{x}(t-1)) \quad (4.8)$$

$$\vec{v}_2(t) = \omega \vec{v}(t-1) + \varphi_1 (\vec{P}_i - \vec{x}(t-1)) + \varphi_2 (\vec{P}_L - \vec{x}(t-1)) \quad (4.9)$$

$$\vec{v}(t) = u \vec{v}_1(t) + (1-u) \vec{v}_2(t) \quad (4.10)$$

$$\vec{x}(t) = \vec{x}(t-1) + \vec{v}(t) \quad (4.11)$$

Sendo:

φ_1 : Número aleatório de distribuição uniforme no intervalo $[0, \varphi_{1max}]$

φ_2 : Número aleatório de distribuição uniforme no intervalo $[0, \varphi_{2max}]$

\vec{P}_i : A melhor posição histórica do indivíduo

\vec{P}_g : A melhor posição global visitada pela população

\vec{P}_L : A melhor posição local visitada pela vizinhança

u : Fator de unificação no intervalo $[0,1]$

\vec{v} : Vetor velocidade

O fator u é um fator de unificação que controla a influência das parcelas globais e locais na evolução da velocidade da população. Com $u=1$ o modelo corresponde ao PSO padrão, cuja vizinhança é igual a toda população. Para o caso em que $u = 0$ a influência da vizinhança é de característica puramente local.

4.2.5 UPSO com representação híbrida

Uma adaptação da abordagem do UPSO com representação híbrida (variáveis reais e binárias) será aqui apresentada. A velocidade e a posição de cada indivíduo podem ser obtidas separando-se as variáveis binárias e reais.

Variáveis reais seguem a seguinte lógica de atualização:

$$\vec{v}_1(t) = \omega_r \vec{v}_r(t-1) + \varphi_1 (\vec{P}_i - \vec{x}_r(t-1)) + \varphi_2 (\vec{P}_G - \vec{x}_r(t-1)) \quad (4.12)$$

$$\vec{v}_2(t) = \omega_r \vec{v}_r(t-1) + \varphi_1 (\vec{P}_i - \vec{x}_r(t-1)) + \varphi_2 (\vec{P}_L - \vec{x}_r(t-1)) \quad (4.13)$$

$$\vec{vr}(t) = u \vec{v}_1(t) + (1-u) \vec{v}_2(t) \quad (4.14)$$

$$\vec{xr}(t) = \vec{xr}(t-1) + \vec{vr}(t) \quad (4.15)$$

Variáveis binárias seguem a seguinte lógica:

$$\vec{v}_3(t) = \omega_b \vec{v}_b(t-1) + \varphi_3 (\vec{P}_i - \vec{x}_b(t-1)) + \varphi_4 (\vec{P}_G - \vec{x}_b(t-1)) \quad (4.16)$$

$$\vec{v}_4(t) = \omega_b \vec{v}_b(t-1) + \varphi_3 (\vec{P}_i - \vec{x}_b(t-1)) + \varphi_4 (\vec{P}_L - \vec{x}_b(t-1)) \quad (4.17)$$

$$\vec{vb}(t) = u \vec{v}_3(t) + (1-u) \vec{v}_4(t) \quad (4.18)$$

$$xb_{id}(t) = \begin{cases} 1 & , se \rho < s(vb_{id}(t)) \\ 0 & , caso contrário \end{cases} \quad (4.19)$$

Sendo:

- \vec{v}_r : Vetor de velocidades das partículas reais
- \vec{x}_r : Vetor de posição das partículas reais
- \vec{v}_b : Vetor de velocidades das partículas binárias
- \vec{x}_b : Vetor de posição das partículas binárias
- i : Índice do indivíduo
- d : Índice da dimensão da partícula

O fluxograma de execução do algoritmo PSO/UPSO está mostrado na Figura 4.4.

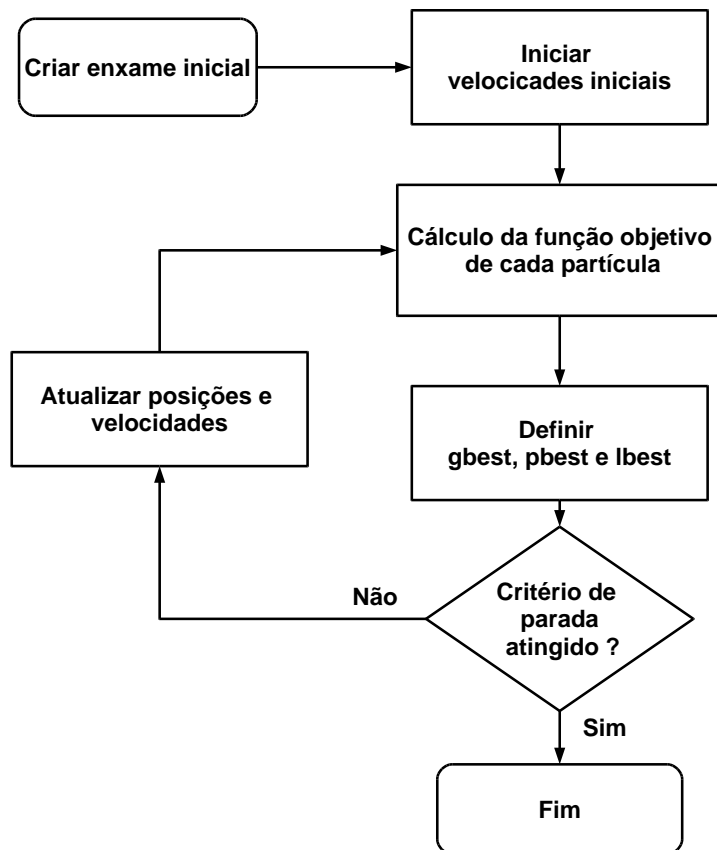


Figura 4.4 – Fluxograma de execução do método PSO/UPSO

4.3 Algoritmo Genético

O Algoritmo Genético é a forma mais conhecida de Algoritmo Evolucionário e foi proposto originalmente por Holland em 1992 [21], sendo uma metaheurística aplicável a uma gama extensa de problemas de otimização.

O método é baseado no conceito biológico de seleção natural, onde espécies mais adaptadas ao seu meio levam vantagem evolutiva em relação às demais, tendendo a produzir descendentes mais propensos a sobreviver e continuar o ciclo evolutivo ao longo de gerações.

A produção de descendentes gera competição entre organismos para a sobrevivência e reprodução, estando condicionada a adaptabilidade do ambiente. A

característica hereditária do método faz com que dentro de uma população os indivíduos tendam a se basear em indivíduos de gerações anteriores. O processo de seleção natural, portanto, faz com que organismos com características mais vantajosas tendam a sobreviver e se reproduzir, enquanto que características menos vantajosas tendem a não ser passadas para as gerações seguintes.

Para a utilização do algoritmo parte-se de uma população de indivíduos (possíveis soluções) sendo estes passados por operadores genéticos de seleção, cruzamento e mutação. Os operadores genéticos atuam de forma a, a partir da análise da qualidade da solução, gerar novas populações que possuam melhores avaliações e conseqüentemente representem uma evolução das soluções ao longo das iterações.

A abordagem inicial do método foi feita com base em problemas de característica binária. Esta representação tem sido a mais aplicada quando utilizado o método do Algoritmo Genético, entretanto, atualmente já existem outros tipos de representação largamente utilizados com resultados mais eficientes como a inteira e híbrida, que trata conjuntamente a representação binária e real.

Entre os principais parâmetros genéticos do método, pode-se citar:

- **Tamanho da população:** indica o número de soluções testadas simultaneamente. Em geral com populações pequenas o desempenho pode cair, enquanto maiores populações requerem maior esforço computacional.
- **Número de Gerações:** indica o número de gerações utilizadas pelo método e está diretamente relacionada ao tamanho da população adotada. Pode-se escolher entre adotar populações maiores com um número menor de iterações, ou uma população menor e um número de iterações mais elevado. O número de gerações necessário em geral depende do caso particular do problema.
- **Taxa de Cruzamento:** Indica a porcentagem da população, excetuando os elementos da elite que será composta por descendentes de cruzamento. Em geral adota-se uma fração alta, de forma a aumentar a diversidade genética.
- **Taxa de Mutação:** Indica a probabilidade de mutação de um gene de acordo com o método especificado. Impede que o valor de um gene fique estagnado em determinado valor ao longo das iterações

4.3.1 Estrutura de um Algoritmo Genético

O algoritmo genético é composto de uma seleção de cromossomos, que são a representação de soluções para um problema em particular. O conjunto de cromossomos é denominado população, enquanto uma variável ou posição de um cromossomo é denominada *gene*. O cromossomo pode ter genes exclusivamente binários, inteiros e/ou reais, dependendo do problema ao qual é aplicado. A interpretação dos genes de um cromossomo é exclusiva de cada problema. Um mesmo conjunto de genes pode representar problemas de características completamente diferentes, podendo o método Algoritmo Genético ser aplicado a problemas de diversos ramos do conhecimento. A interpretação de um cromossomo depende basicamente da função aptidão, próximo elemento fundamental de um algoritmo genético.

A função aptidão é a que avalia a qualidade de um cromossomo, ou seja a qualidade de uma determinada solução. No processo evolutivo os indivíduos com mais aptidão ao ambiente são os mais propensos a sobreviver e os com mais chance de se reproduzirem. Analogamente no processo do algoritmo genético, os cromossomos que apresentam maior aptidão são os principais escolhidos para reprodução nas próximas gerações de população.

Resumidamente, o método do Algoritmo Genético funciona da seguinte forma: Uma população inicial de cromossomos ou indivíduos é gerada. Esta população passa por uma avaliação calculada pela função de aptidão, Os indivíduos mais bem avaliados, ou indivíduos mais propensos ao meio, são selecionados pela etapa de Seleção. Os indivíduos selecionados nesta etapa passam por uma etapa de Cruzamento, ou Reprodução, dando origem a uma nova população. Os indivíduos antigos e a população anterior serão substituídos pela nova população gerada, sendo os novos indivíduos passados por uma etapa de Mutação. O procedimento se repete até que seja atingido algum critério de parada, que pode ser um número total de iterações ou certo valor de convergência atingido. O procedimento citado é mostrado na Figura 4.5.

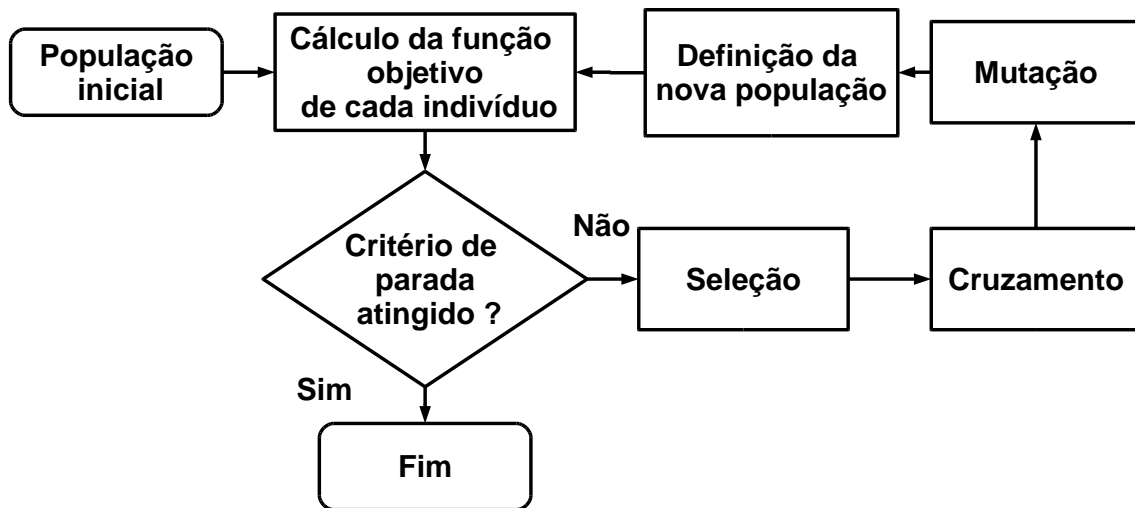


Figura 4.5 – Fluxograma de execução do método Algoritmo Genético

A seguir serão tratados com mais detalhes a função de cada um dos operadores genéticos citados.

4.3.2 Seleção

O operador de seleção busca obter os indivíduos mais aptos de uma população, ou seja, as soluções mais bem avaliadas para serem priorizadas no processo evolutivo. Na literatura, são listados diferentes métodos e critérios utilizados no processo de seleção. A escolha dos métodos pode interferir diretamente no desempenho do algoritmo, induzindo um processo evolutivo de característica diferente.

O processo de Seleção pode influenciar no desempenho do algoritmo nos seguintes pontos [22]:

- Pode acelerar ou retardar a convergência do método
- Pode ser menos ou mais agressivo no aproveitamento das melhores soluções
- Selecionando os melhores indivíduos, pode-se descartar soluções potenciais, porém de avaliação ruim.
- Ao permitir que indivíduos com avaliação ruim participem do processo evolutivo, soluções ruins podem tender a permanecer na população ao longo das gerações.

O conceito fundamental deste processo é o de privilegiar os indivíduos com função de avaliação mais alta, sem necessariamente desprezar completamente aquelas com

função de avaliação mais baixa. Soluções com função de avaliação menor podem também possuir características genéticas favoráveis, que devidamente aproveitadas tendem a melhorar as soluções. A seguir serão apresentados alguns dos principais métodos de seleção utilizados na bibliografia.

A seleção truncada avalia todos os indivíduos da população e seleciona os “ k ” mais bem avaliados. Os indivíduos são ordenados em função de sua avaliação e somente aqueles de melhor colocação participam do processo de seleção. Este método de seleção favorece diretamente os indivíduos mais bem avaliados e impede que soluções mal avaliadas sejam selecionadas.

O método de “Torneio” cria N subgrupos de k indivíduos, de forma aleatória, podendo haver repetição entre os mesmos. No torneio, é feita uma competição entre os indivíduos, podendo ser selecionados diretamente os mais bem avaliados em cada grupo, ou se adotar, uma abordagem estocástica onde os indivíduos mais e menos bem avaliados possuem probabilidades diferentes de escolhas.




Figura 4.6 – Método de Seleção por Torneio

O método de Seleção “Roleta” dá a cada cromossomo/indivíduo da população uma probabilidade de ser escolhido proporcional a sua aptidão relativa às demais aptidões da solução. Soluções com melhor avaliação terão mais chances de ser escolhidas, enquanto soluções de pior avaliação terão menos chances. O método pode ser analogamente comparado a um sorteio de roleta, cujas possibilidades de escolha têm probabilidades diferentes.

Indivíduo (S_i)	Aptidão $f(S_i)$	Aptidão Relativa
S1	2,23	0,14
S2	7,27	0,47
S3	1,05	0,07
S4	3,35	0,21
S5	1,69	0,11




Figura 4.7 – Método da Roleta baseado em Aptidão Relativa

O método de Seleção por Amostragem, similarmente ao método de Seleção por “Roleta”, simula uma roleta com n cursores igualmente espaçados e com proporções iguais a aptidão relativa. O processo de seleção pega os indivíduos selecionados pelos respectivos cursores. Este método apresenta resultados menos variantes quando comparado ao método de Roleta.

4.3.3 Elitismo

O elitismo é um operador que força o algoritmo genético a preservar um número de melhores soluções da população em cada geração. Estes indivíduos não são perdidos durante o processo de reprodução, possibilitando ao algoritmo manter e aproveitar as características destas soluções.

O elitismo possui a vantagem de permitir melhoras no desempenho do Algoritmo Genético ao guardar as melhores soluções já encontradas, não sendo estas perdidas nos demais processos evolutivos. Entretanto, o elitismo pode também ser responsável por uma possível diminuição da diversidade populacional, ao forçar determinadas soluções na evolução do método.

4.3.4 Operadores Genéticos

Os operadores genéticos são a lógica por trás da atuação de um algoritmo genético. Eles determinam como o algoritmo evolui ao longo das iterações, como novos indivíduos são criados e como são selecionados os melhores indivíduos.

4.3.4.1 Cruzamento ou Crossover

O operador Crossover (ou cruzamento) é a fonte de quase toda variação genética do AG. A etapa de cruzamento é a etapa responsável por formar novos indivíduos, indivíduos filhos, a partir de indivíduos previamente presentes, indivíduos pais. A ideia da recombinação é simular a mistura de material genético que ocorre durante a reprodução para gerar novos indivíduos.

Os indivíduos selecionados para a etapa de cruzamento ou *crossover* são obtidos na etapa de seleção. Os indivíduos filhos gerados por carregarem os genes dos indivíduos pais que passaram por um processo prévio de seleção tendem probabilisticamente a obter um valor de aptidão mais favorável. A taxa e o tipo de cruzamento determinam a frequência da troca de informações entre os indivíduos e de que maneira as informações são recombinadas.

Alguns dos principais métodos de cruzamento são: Cruzamento de ponto único, Cruzamento de dois pontos, Cruzamento uniforme, Cruzamento aritmético, entre outros [22].

A Figura 4.8 mostra o tipo de cruzamento uniforme, onde os indivíduos pais dão origem a indivíduos filhos, sendo cada elemento do genoma do filho sorteado aleatoriamente de um dos pais indivíduos pais.




Figura 4.8 – Cruzamento uniforme.

A Figura 4.9 mostra o esquema de cruzamento de dois pontos, onde os indivíduos pais dão origem a indivíduos filhos, através da mistura genética feita através

de dois pontos de divisão principais. O cruzamento de ponto único se assemelha a este esquema, tendo, porém um único ponto de corte.

O cruzamento de forma aritmética permite que os indivíduos filhos sejam obtidos pela média aritmética entre dois indivíduos pais. Pode-se também adotar a média ponderada entre dois vetores empregando um peso de valor aleatório para cada um dos indivíduos pais.




Figura 4.9 – Cruzamento de dois pontos.

4.3.4.2 Mutaç o

O operador de muta o   respons vel por manter a diversidade gen tica da popula o, realizando altera es em um ou mais genes de um indiv duo. Isto possibilita o aparecimento de novos indiv duos, o que torna o algoritmo gen rico capaz de encontrar solu es distintas das j  exploradas.

A muta o   um mecanismo importante, pois previne a estagna o da popula o, provocando o aumento da diversidade. A muta o ocorre ap s a etapa de cruzamento, onde   criada uma nova popula o. Uma probabilidade de ocorr ncia de muta o   definida como a indica o ou n o se haver  a altera o em um gene do indiv duo. Em geral, deseja-se uma probabilidade de muta o baixa, de forma a evitar que a popula o evolua de forma totalmente aleat ria. A Figura 4.10 mostra um exemplo do processo de muta o nos genes de um indiv duo.




Figura 4.10 – Exemplo de mutação uniforme para codificação de valores reais e binários.

Alguns dos principais métodos de mutação são listados a seguir, para soluções binárias ou de ponto flutuante (valores reais).

- Troca de bit: operador de mutação que simplesmente inverte o valor de um dado gene pelo seu inverso. Este operador é compatível somente com codificações binárias.
- Vizinhança: operador que substitui o valor de um dado gene por um valor escolhido aleatoriamente da vizinhança. Aplicável em codificações inteira ou ponto flutuante.
- Não uniforme: operador que realiza mutação segundo uma probabilidade que diminui de acordo que o número de gerações aumenta. Usado em codificações inteiras ou ponto flutuante.
- Uniforme: operador de mutação que substitui o valor de um gene escolhido com um valor aleatório uniforme selecionado dentro de um intervalo de valores pré-determinado. O operador de mutação uniforme é compatível com codificações inteira e ponto flutuante.
- Gaussiana: operador de mutação que substitui um valor de um gene aleatório de acordo com distribuição gaussiana. Este operador funciona com codificações inteira e ponto flutuante.

Além destes principais operadores de mutação podem ser adotados outros critérios de mutação, inclusive criados critérios próprios que resolvam determinados tipos de problema.

Definido o critério de mutação, deve-se definir também o fator de probabilidade de mutação, que indica a probabilidade de um gene de uma solução sofrer processo de mutação.

4.4 Algoritmo de Evolução Diferencial

O Algoritmo de Evolução Diferencial (DE) foi proposto por Storn e Prince em 1995 [23] e é um método metaheurístico estocástico originado nos mecanismos de seleção natural. O método se destaca por sua característica simples, porém poderosa de resolver problemas de otimização difícil.

Entre as principais características do método estão:

- Algoritmo simples de fácil entendimento e reprodução;
- Poucos parâmetros de controle para conduzir a otimização;
- Eficaz trabalhando com populações pequenas;
- Variáveis tratadas como números reais;
- Robusto quanto a ótimos locais, utilizando diferentes regiões no espaço de busca.

O primeiro conceito a ser entendido no algoritmo DE é o conceito de população. Uma população é composta por N indivíduos, ou vetores, que representam soluções para um problema de otimização, representado por uma função objetivo. Os vetores cobrem o espaço de solução, realizando um processo estocástico de seleção e busca de um ponto ótimo. A função objetivo visa retornar ao método um valor de avaliação de cada um dos vetores de solução, que determina o quão boa ou ruim é uma solução para o problema estudado. A ideia geral da evolução do método é gerar novos vetores de tentativas, obtidos a partir da própria população, cuja determinação é feita através da criação de vetores de diferença. Tal processo ocorre através dos operadores genéticos, assim como no Algoritmo Genético.

A população é criada, e em geral determinada de maneira uniforme (não havendo conhecimento prévio sobre o problema) e de tamanho fixo, sendo enfim submetida a operadores evolutivos sendo eles: Mutação, Cruzamento e Seleção. Os operadores evolutivos são reproduzidos até que uma condição de parada seja atingida, que pode ser um erro mínimo pré-definido ou um número máximo de iterações. O propósito da formulação do método, assim como dos demais métodos metaheurísticos de base populacional é seguir uma solução ótima mantendo a diversidade populacional e evitando convergências prematuras. Uma das principais peculiaridades do método é não

aceitar soluções novas que tenham avaliação pior que as anteriores, diferentemente do que ocorre nos métodos do PSO e do Algoritmo Genético.

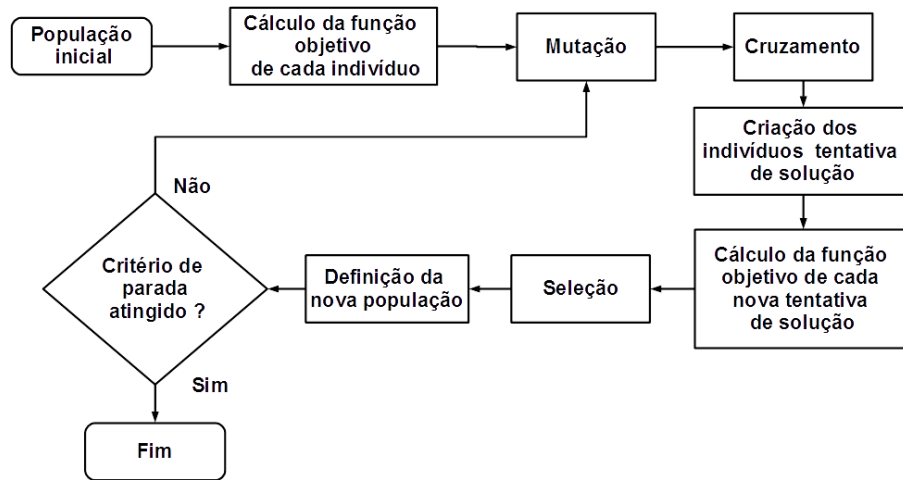


Figura 4.11 – Fluxograma de execução do método de Evolução Diferencial

4.4.1 Operadores Genéticos

O método de Evolução Diferencial, assim como o Algoritmo Genético é baseado em operadores genéticos. A formulação adotada para os operadores genéticos do método de Evolução Diferencial é mostrada a seguir.

4.4.1.1 Mutação

O processo de mutação tem como objetivo a criação de novos vetores mutações para a população existente. No processo de mutação são escolhidos, para cada vetor, três indivíduos distintos da população, entre todos os indivíduos da mesma. Para uma população de N indivíduos de dimensão D é criada então uma matriz de vetores diferença, sendo esta determinada da seguinte forma:

$$V_{i,G+1} = X_{r1,G} + F \cdot (X_{r2,G} - X_{r3,G}) \quad (4.20)$$

Em que:

$$V_{i,G} = \{v_{i,1,G}, v_{i,2,G}, \dots, v_{i,D,G}\} \quad (4.21)$$

$$X_{i,G} = \{x_{i,1,G}, x_{i,2,G}, \dots, x_{i,D,G}\} \quad (4.22)$$

Sendo:

$X_{i,G}$:	Vetor posição do indivíduo i na geração G
$x_{i,d,G}$:	Posição do indivíduo i na dimensão d na geração G
$V_{i,G}$:	Vetor mutação para o indivíduo i na geração G
$v_{i,d,G}$:	Elemento do vetor mutação do indivíduo i na dimensão d na geração G
F :	Fator de mutação
r_1, r_2, r_3 :	Indivíduos aleatórios da população, sendo: $r_1, r_2, r_3 \in \{1, 2, \dots, NP\}$ e $r_1 \neq r_2 \neq r_3 \neq i$

O fator F é chamado de fator de mutação e controla a amplificação da variação diferencial entre as parcelas. O vetor mutação é criado para cada indivíduo, a partir da diferença entre outros três indivíduos distintos, sendo necessário dessa maneira uma quantidade mínima de quatro indivíduos na população.

4.4.1.2 Cruzamento

O objetivo deste operador é gerar um vetor que combine os vetores mutação com os vetores originais da população. A este novo vetor gerado será dado o nome de “vetor tentativa”. O novo vetor será um cruzamento entre dois vetores, o vetor original e o vetor de diferenças, obtido na etapa de Mutação. O cruzamento é feito da seguinte forma:

$$u_{ij,G+1} = \begin{cases} v_{ij,G+1} & \text{se } rand() \leq CR \\ x_{ij,G} & \text{caso contrário} \end{cases} \quad (4.23)$$

$$U_{i,G} = \{u_{i,1,G}, u_{i,2,G}, \dots, u_{i,D,G}\} \quad (4.24)$$

Sendo:

$U_{i,G}$:	Vetor tentativa para o indivíduo i na geração G
$u_{ij,G}$:	Elemento do vetor tentativa i , na dimensão d e geração G
CR :	Fator de <i>crossover</i>
$rand()$:	Número aleatório no intervalo (0,1)

Em geral, se adota uma regra para que ao menos um elemento seja substituído, caso contrário o vetor de tentativa será o mesmo que o vetor solução original. O cruzamento conforme indicado é feito elemento a elemento do vetor. Caso o número

aleatório sorteado seja menor que o fator de *crossover* o elemento do vetor tentativa será igual ao vetor mutação, caso contrário será igual ao elemento do vetor original.

Esta lógica está representada na Figura 4.12.




Figura 4.12 – Formação do vetor tentativa a partir da etapa de mutação.

4.4.1.3 Seleção

O último operador genético do método de Evolução Diferencial é o operador de Seleção. O operador de Seleção parte da função objetivo para identificar entre os vetores tentativa e os vetores soluções atuais quais possuem a melhor aptidão. A partir das matrizes de população e matrizes de vetores tentativas, são comparados elemento a elemento os indivíduos das duas populações. O indivíduo que possuir a melhor aptidão será o novo indivíduo da população. Desse modo, a nova geração será composta dos melhores indivíduos das duas matrizes, encaminhando a resposta sempre na direção de melhorar ou manter sua aptidão. Assim, o método de Evolução Diferencial não permite soluções novas com aptidões piores que as já encontradas.

A formulação do operador de Seleção é feita da seguinte forma:

$$X_{i,G+1} = \begin{cases} U_{i,G} & \text{se } f(U_{i,G}) \leq f(X_{i,G}) \\ X_{i,G} & \text{caso contrário} \end{cases} \quad (4.25)$$

Sendo:

- $X_{i,G}$: Vetor solução do indivíduo i na geração G
- $X_{i,G+1}$: Vetor solução do indivíduo i na geração $G + 1$
- $U_{i,G}$: Vetor tentativa do indivíduo i na geração G

$f(\dots)$: Função Objetivo

4.4.2 Evolução Diferencial Aprimorado

O método de Evolução Diferencial precisa da definição dos seguintes fatores:

CR : Fator de *crossover*

F : Fator de mutação

A definição adequada de tais parâmetros é importante para uma boa convergência do método, porém uma dificuldade adicional na calibração do mesmo. Uma abordagem alternativa, onde os parâmetros são atualizados de forma adaptativa, foi proposta em [24]. A abordagem proposta faz a atualização dos parâmetros de acordo com sequências caóticas. Esta abordagem permite ao algoritmo um aumento da capacidade de exploração e contorna a necessidade da calibração manual do método.

Na abordagem proposta por ZHANG [24] o fator de mutação e o fator de *crossover* são definidos a cada iteração da seguinte forma:

$$F(G) = \mu \cdot F(G - 1) \cdot [1 - F(G - 1)] \quad (4.26)$$

$$CR(G) = \mu \cdot CR(G - 1) \cdot [1 - CR(G - 1)] \quad (4.27)$$

$$F(G) \in (0,1)$$

$$CR(G) \in (0,1)$$

Sendo:

G : Número da geração ou iteração do método de Evolução Diferencial.

μ : Parâmetro de controle.

Como restrição para a aplicação do método, o parâmetro de controle μ e os valores iniciais do fator de mutação e de *crossover* devem obedecer as seguintes condições:

$$\mu \in (0,4)$$

$$F(0) \in (0,1), \quad F(0) \notin [0, 0,25, 0,5, 0,75]$$

$$CR(0) \in (0,1), \quad CR(0) \notin [0, 0,25, 0,5, 0,75]$$

CAPÍTULO 5

IMPLEMENTAÇÃO COMPUTACIONAL

5.1 Introdução

Neste Capítulo são apresentadas as informações relativas à implementação computacional do problema de otimização da operação diária de usinas hidrelétricas em cascata utilizadas neste trabalho. Neste Capítulo estão presentes: o sistema base adotado: sistema hidrelétrico em cascata composto por quatro usinas, a estratégia de solução utilizada: indicação quanto ao número de variáveis e a característica das mesmas, a definição do problema de otimização: definição da função objetivo e das restrições do problema e os resultados das simulações frente a diferentes métodos, diferentes condições e diferentes cenários.

Os métodos de otimização escolhidos foram três métodos metaheurísticos: Algoritmo de Enxame de Partículas Modificado (UPSO), Algoritmo Genético (AG) e Algoritmo de Evolução Diferencial (DE). Os métodos foram testados de forma a validar sua eficácia em condições de operação variadas, testando sua eficiência, reprodutibilidade e variação quanto à qualidade das soluções.

5.2 Sistema Teste

Nesta Seção serão apresentados os dados do sistema hidrelétrico em cascata utilizado neste trabalho. Os dados apresentados seguem a modelagem presente no Capítulo 3.

5.2.1 Dados do Sistema

O sistema hidrelétrico considerado neste trabalho é um sistema composto por quatro usinas hidrelétricas, cuja configuração de cascata é mostrada na Figura 5.1. Os dados do sistema apresentados neste trabalho foram baseados nos dados presentes em [2].




Figura 5.1 – Esquema do sistema de hidrelétricas estudado

No sistema há um total de quatro usinas hidrelétricas com reservatórios, estando as usinas UHE1 e UHE2 a montante da usina UHE3 que por sua vez está a montante da usina UHE4. O tempo de deslocamento das águas entre as usinas é considerado constante e é indicado na Tabela 5.1.

Tabela 5.1 – Tempo de deslocamento entre as usinas

Usinas		Usinas Para			
		UHE1	UHE2	UHE3	UHE4
Usinas De	UHE1	-	1 h	-	-
	UHE2	-	-	1 h	-
	UHE3	-	-	-	1 h
	UHE4	-	-	-	-

As quatro usinas geradoras (UHE1, UHE2, UHE3 e UHE4) contêm cinco tipos de unidades em um total de 14 máquinas instaladas. As 14 unidades geradoras foram nomeadas de UG01 a UG14, possuindo cada usina hidrelétrica uma ordem pré-definida de despacho. Os tipos de unidades geradoras por usina e a ordem de despacho de cada usina podem ser vistos na Tabela 5.2.

Tabela 5.2 – Ordem de despacho das máquinas para cada uma das usinas hidrelétricas.

Unidades Geradoras														
Unid./ Usina	Tipo 1			Tipo 2			Tipo 3			Tipo 4			Tipo 5	
	UG 01	UG 02	UG 03	UG 04	UG 05	UG 06	UG 07	UG 08	UG 09	UG 10	UG 11	UG 12	UG 13	UG 14
UHE1	1	2	3	-	-	-	-	-	-	-	-	-	-	-
UHE2	-	-	-	1	2	3	-	-	-	-	-	-	-	-
UHE3	-	-	-	-	-	-	1	2	3	-	-	-	-	-
UHE4	-	-	-	-	-	-	-	-	-	1	2	3	4	5

Na Tabela 5.3 estão indicados os limites máximos e mínimos de potência ativa para cada tipo de unidade geradora do sistema.

Tabela 5.3 – Limites mínimos e máximos de potência para cada tipo de unidade geradora

Unidades	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5
P_{min} (MW)	172,0	136,0	223,0	200,0	200,0
P_{max} (MW)	293,3	232,8	380,0	290,0	290,0

Os coeficientes da curva de eficiência dos cinco tipos de máquinas, indicados na Equação (3.11), são mostrados na Tabela 5.4.

Tabela 5.4 – Coeficientes de rendimento da turbina para cada tipo de máquina do sistema.

Coefic.	c_0	c_1	c_2	c_3	c_4	c_5
Tipo 1	$3,59 \cdot 10^{-1}$	$5,54 \cdot 10^{-3}$	$1,99 \cdot 10^{-3}$	$1,05 \cdot 10^{-5}$	$-2,73 \cdot 10^{-5}$	$-9,43 \cdot 10^{-6}$
Tipo 2	$3,59 \cdot 10^{-1}$	$5,85 \cdot 10^{-3}$	$2,37 \cdot 10^{-3}$	$1,33 \cdot 10^{-5}$	$-3,04 \cdot 10^{-5}$	$-1,34 \cdot 10^{-5}$
Tipo 3	$6,90 \cdot 10^{-2}$	$3,01 \cdot 10^{-3}$	$5,56 \cdot 10^{-3}$	$5,84 \cdot 10^{-5}$	$-4,64 \cdot 10^{-6}$	$-3,64 \cdot 10^{-5}$
Tipo 4	$2,45 \cdot 10^{-1}$	$2,89 \cdot 10^{-3}$	$6,66 \cdot 10^{-3}$	$1,87 \cdot 10^{-5}$	$-9,18 \cdot 10^{-6}$	$-5,74 \cdot 10^{-5}$
Tipo 5	$3,59 \cdot 10^{-1}$	$3,23 \cdot 10^{-3}$	$3,44 \cdot 10^{-3}$	$1,07 \cdot 10^{-5}$	$-9,26 \cdot 10^{-6}$	$-2,84 \cdot 10^{-5}$

As vazões turbinadas máxima e mínima podem ser determinadas pelas Equações (3.13) e (3.14), cujos coeficientes estão presentes na Tabela 5.5 para a determinação da vazão máxima, e na Tabela 5.6 para a determinação da vazão mínima.

Tabela 5.5 – Coeficientes de vazão turbinada máxima por tipo de máquina

Coeficientes	d_0	d_1	d_2	d_3
Tipo 1	$2,582 \cdot 10^3$	$-4,871 \cdot 10^1$	$3,187 \cdot 10^{-1}$	$-6,759 \cdot 10^{-4}$
Tipo 2	$1,870 \cdot 10^3$	$-4,125 \cdot 10^1$	$3,250 \cdot 10^{-1}$	$-8,295 \cdot 10^{-4}$
Tipo 3	$1,502 \cdot 10^4$	$-4,867 \cdot 10^2$	5,388	$-1,973 \cdot 10^{-2}$
Tipo 4	$5,952 \cdot 10^3$	$-1,949 \cdot 10^2$	2,211	$-8,209 \cdot 10^{-3}$
Tipo 5	$5,952 \cdot 10^3$	$-1,949 \cdot 10^2$	2,211	$-8,209 \cdot 10^{-3}$

Tabela 5.6 – Coeficientes de vazão turbinada mínima por tipo de máquina

Coeficientes	e_0	e_1	e_2	e_3
Tipo 1	$2,257 \cdot 10^2$	-2,694	$2,340 \cdot 10^{-2}$	$-7,038 \cdot 10^{-5}$
Tipo 2	$1,719 \cdot 10^2$	-2,279	$1,997 \cdot 10^{-2}$	$-6,062 \cdot 10^{-5}$
Tipo 3	$-1,162 \cdot 10^2$	$1,109 \cdot 10^1$	$-1,315 \cdot 10^{-1}$	$4,751 \cdot 10^{-4}$
Tipo 4	$5,488 \cdot 10^2$	$-1,080 \cdot 10^1$	$9,369 \cdot 10^{-2}$	$-2,844 \cdot 10^{-4}$
Tipo 5	$5,488 \cdot 10^2$	$-1,080 \cdot 10^1$	$9,369 \cdot 10^{-2}$	$-2,844 \cdot 10^{-4}$

As quatro usinas possuem características próprias. A seguir serão mostrados os coeficientes e os limites operativos de cada uma. A Tabela 5.7 mostra o volume mínimo e máximo permitido no reservatório de cada uma das usinas.

Tabela 5.7 – Volumes mínimos e máximos permitidos nos reservatórios por usina

Usinas	UHE1	UHE2	UHE3	UHE4
Vol. mínimo (hm ³)	1320	2711	2283	4300
Vol. máximo (hm ³)	1477	4904	3348	5100

Os coeficientes dos polinômios de cota a montante e de cota a jusante de cada reservatório, Equação (3.3) e Equação (3.4), estão mostrados na Tabela 5.8 e Tabela 5.9 respectivamente.

Tabela 5.8 – Coeficientes de cota a montante por usina

Coeficientes	a_0	a_1	a_2	a_3	a_4
UHE1	$2,43 \cdot 10^2$	1,07	$-1,10 \cdot 10^{-3}$	$5,21 \cdot 10^{-7}$	$-9,24 \cdot 10^{-11}$
UHE2	$5,40 \cdot 10^2$	$4,46 \cdot 10^{-2}$	$-8,15 \cdot 10^{-6}$	$9,32 \cdot 10^{-10}$	$-4,39 \cdot 10^{-14}$
UHE3	$4,01 \cdot 10^2$	$5,01 \cdot 10^{-2}$	$-1,57 \cdot 10^{-5}$	$3,30 \cdot 10^{-9}$	$-2,88 \cdot 10^{-13}$
UHE4	$3,35 \cdot 10^2$	$6,78 \cdot 10^{-3}$	0	0	0

Tabela 5.9 – Coeficientes de cota a jusante por usina

Coeficientes	b_0	b_1	b_2	b_3	b_4
UHE1	$4,70 \cdot 10^2$	$1,01 \cdot 10^{-2}$	$-5,59 \cdot 10^{-6}$	$1,73 \cdot 10^{-9}$	$-2,01 \cdot 10^{-13}$
UHE2	$4,80 \cdot 10^2$	$1,62 \cdot 10^{-3}$	$-4,52 \cdot 10^{-8}$	0	0
UHE3	$3,72 \cdot 10^2$	$1,93 \cdot 10^{-3}$	$-8,53 \cdot 10^{-8}$	$2,38 \cdot 10^{-12}$	$-2,62 \cdot 10^{-17}$
UHE4	$2,64 \cdot 10^2$	$9,15 \cdot 10^{-4}$	$-6,71 \cdot 10^{-9}$	0	0

Os limites de vazão defluente e limites de rampa de variação de vazão por usina estão definidos na Tabela 5.10.

Tabela 5.10 – Vazão defluente máxima e mínima por usina.

Usinas	U_r^{min} (m ³ /s)	U_r^{max} (m ³ /s)	rm^{max}
UHE1	150	800	400
UHE2	150	800	400
UHE3	200	1500	750
UHE4	220	1500	750

As perdas hidráulicas, calculadas pelas Equações (3.6), (3.7) e (3.8), possuem os seguintes coeficientes, dados por usina, presentes na Tabela 5.11.

Tabela 5.11 – Coeficientes de perdas hidráulicas por usina

Coeficientes	k_s	k_p	k_{pu}
UHE1	$4,183 \cdot 10^{-5}$	$8,889 \cdot 10^{-5}$	0
UHE2	$4,484 \cdot 10^{-5}$	$9,528 \cdot 10^{-5}$	0
UHE3	$2,252 \cdot 10^{-6}$	$4,786 \cdot 10^{-6}$	0
UHE4	$6,245 \cdot 10^{-6}$	$1,314 \cdot 10^{-5}$	0

Os coeficientes de eficiência da turbina e do gerador, n_t e n_g , adotados neste trabalho estão presentes na Tabela 5.12.

Tabela 5.12 – Coeficientes de eficiência das turbinas e dos geradores por tipo de máquina

Unidades geradoras	n_t	n_g
Tipo 1	0,98	0,97
Tipo 2	0,98	0,97
Tipo 3	0,98	0,97
Tipo 4	0,98	0,97
Tipo 5	0,98	0,97

5.2.2 Cenário Base

Nesta seção será indicado o cenário de operação definido como Cenário Base. Um cenário de operação é definido a partir de condições de vazão afluente, volume inicial e demanda.

O valor de vazão incremental considerado para o Cenário Base é considerado constante em todos os intervalos de tempo e de valor, por usina, mostrado na Tabela 5.13. Os volumes iniciais neste cenário, presentes na mesma tabela, colocam todos os reservatórios com o mesmo percentual de volume útil para ser utilizado, igual a 50% de sua capacidade.

Tabela 5.13 – Condições de operação consideradas para o Caso Base.

Caso Base				
Operação	UHE1	UHE2	UHE3	UHE4
Volume útil (%)	50	50	50	50
Vazão incremental (m ³ /s)	559	463	475	669

A curva de demanda do sistema ao longo do dia está indicada na Tabela 5.14. Os valores são discretizados em intervalos horários.

Tabela 5.14 – Valores da curva de demanda para o Caso Base

Curva de demanda												
Tempo (h)	t=1	t=2	t=3	t=4	t=5	t=6	t=7	t=8	t=9	t=10	t=11	t=12
Demanda (MW)	940	1190	2000	2180	2595	2565	2750	3000	2895	3265	3450	3200
Tempo (h)	t=13	t=14	t=15	t=16	t=17	t=18	t=19	t=20	t=21	t=22	t=23	t=24
Demanda (MW)	2720	2465	2765	2265	2750	2450	2365	2465	1845	1390	940	940

A Figura 5.2 mostra a variação da demanda horária ao longo das 24 horas. A curva de demanda apresenta valor de pico na décima primeira hora de simulação.




Figura 5.2 - Curva de Demanda – Cenário 1 (Caso Base).

Os limites mínimos de reserva girante para o conjunto de usinas são adotados como um décimo do valor da demanda no respectivo intervalo de tempo.

5.3 Estratégia de Solução

De forma a se definir uma estratégia de solução, foram inicialmente determinadas quais as variáveis necessárias para se caracterizar uma solução do problema de otimização da geração hidrelétrica. O problema consiste em definir quais unidades geradoras serão despachadas e quanto de potência cada unidade irá despachar.

Para a determinação da operação ou não de cada unidade geradora serão adotadas variáveis inteiras ou binárias, que indicam o estado de cada máquina ou o número de máquinas ligadas. O despacho de cada máquina será determinado a partir da vazão turbinada por unidade geradora, representado por variáveis reais. O problema terá característica inteira-mista, ou seja, terá variáveis binárias/inteiras e variáveis de característica real. A estratégia de solução adotada para este problema deve conseguir tratar simultaneamente os dois tipos de variáveis.

Como métodos de solução, serão utilizadas neste trabalho três diferentes metaheurísticas: Algoritmo de Otimização por Enxame de Partículas Unificado (UPSO), Algoritmo Genético (AG) e Algoritmo de Evolução Diferencial (DE), apresentadas no Capítulo 4. Os métodos tratados abordam o problema a partir de um conjunto de soluções candidatas, em busca de soluções ótimas. A diferenciação dos métodos se dá pela forma como evoluem ao longo das iterações e na forma como novas soluções são geradas.

Uma das vantagens da utilização de metaheurísticas neste tipo de problema é a não necessidade de utilização de métodos rebuscados para a obtenção de uma solução matematicamente ótima, o que se torna de grande complexidade ao tratar o problema de tais características de modelagem. Metaheurísticas, por se tratarem de métodos de busca, tratam o problema de forma genérica, cabendo à avaliação ou não de boas soluções à uma modelagem apropriada da função objetivo e das soluções candidatas. Outra vantagem desta estratégia de solução é a característica populacional dos métodos apresentados, o que possibilita a paralelização e a avaliação simultânea de diversas soluções candidatas. A estratégia de solução adotada para os três métodos propõe a mesma representação dos indivíduos, mesma função objetivo e mesmas penalidades de restrições.

5.3.1 Representação das Soluções Candidatas

No problema de otimização da operação da geração hidrelétrica são abordados simultaneamente dois tipos de subproblemas: o problema de alocação de unidades e o problema de despacho energético ótimo. Variáveis binárias e variáveis reais serão utilizadas respectivamente para a solução de cada subproblema.

O problema de alocação de unidades apresenta como variáveis de estado a quantidade de unidades geradoras despachadas por usina, enquanto o problema de despacho energético por unidade apresenta como variáveis a vazão turbinada em cada máquina.

As soluções candidatas, também chamadas de indivíduos dos métodos metaheurísticos, possuem característica mista: variáveis reais e variáveis binárias. Trata-se, portanto, de um problema de otimização binário-real. Estes dois tipos de variáveis seguem a seguinte lógica:

- Variáveis reais: Indicam a vazão turbinada por unidade geradora, por tipo de turbina, por intervalo de tempo, caso a máquina esteja despachada. Caso contrário, a vazão turbinada será zero.
- Variáveis binárias: Indicam o número de unidades geradoras despachadas, por usina, por intervalo de tempo.

5.3.1.1 Representação das Variáveis Reais

Na determinação da vazão turbinada de uma máquina, por tipo de unidade geradora, por usina, por intervalo de tempo, será necessária uma variável real. Ou seja, unidades do mesmo tipo na mesma usina, caso despachadas, turbinam a mesma quantidade de água. Esta abordagem se justifica pelo fato de o ponto ótimo de operação entre unidades geradoras idênticas, operando na mesma usina, ser operando com despachos iguais. Na prática, esta operação também evita desgaste desigual entre unidades geradoras idênticas, o que ocorreria caso as mesmas operassem com despachos diferentes.


A dimensão da parcela real do problema será dependente do número de unidades geradoras por usina, da quantidade de usinas e da quantidade de intervalos de tempo considerados. Para o problema apresentado neste trabalho, a dimensão da parcela real será calculada conforme apresentado na Tabela 5.15.

Tabela 5.15 – Determinação da parcela real.


Usinas	Tipos de unidades	Nº de variáveis
UHE1	1	1
UHE2	1	1
UHE3	1	1
UHE4	2	2
	Total	5
	(24 intervalos)	120

Neste trabalho será considerado um intervalo de simulação de vinte e quatro horas, com discretização horária e vinte e quatro períodos de tempo. No total são cinco tipos de unidades geradoras distribuídas em quatro usinas hidrelétricas. A dimensão total da parcela real, conforme indicado na Tabela 5.15, terá cento e vinte variáveis. Um exemplo da representação da parcela real para um indivíduo da população é mostrado na Figura 5.3.

Variáveis Reais										
1	2	3	4	5	...	116	117	118	119	120
Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5	...	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5
158,5	110,2	164,7	184,9	131,0	...	169,3	108,3	190,1	188,3	113,8



t=1



t=24

Figura 5.3 – Exemplo da parcela real de um indivíduo ou solução.

5.3.1.2 Representação das Variáveis Binárias

As variáveis binárias indicam a quantidade de unidades despachadas por tipo de unidade geradora, por usina, por intervalo de tempo. A dimensão do problema depende do número de diferentes tipos de unidade por usina, do número de usinas e do número de intervalos de tempo.

No sistema estudado, a quantidade de usinas consideradas, a quantidade de unidades geradoras por usina e os diferentes tipos de unidades geradoras, estão presentes na Tabela 5.16.

Tabela 5.16 – Determinação da parcela binária.

Unidades	Nº de unidades	Usina	Nº de unidades	Nº de bits
Tipo 1	3	UHE1	3	2
Tipo 2	3	UHE2	3	2
Tipo 3	3	UHE3	3	2
Tipo 4	2	UHE4	5	3
Tipo 5	3			
			Total	9
			(24 intervalos)	216

O número de unidades despachadas por usina, de acordo com o número de bits, está mostrado na Tabela 5.17.

Tabela 5.17 – Condições de alocação de unidades adotada com 2 e 3 bits.

Estados possíveis		
2 bits	3 bits	Nº de unidades
00	000	0
01	001	1
10	010	2
11	011	3
-	100	4
-	101/ 110 /111	5

Pode-se observar que na usina UHE4 há dois tipos de unidades geradoras, que são despachadas segundo a prioridade de despacho previamente estabelecida pela operação. A mesma é feita de acordo com a Tabela 5.2, sendo as unidades do Tipo 4 despachadas antes das usinas do Tipo 5.

No total, duzentos e dezesseis variáveis binárias são utilizadas para a representação deste problema em um período de vinte e quatro horas com discretização horária. Uma representação da parcela binária do indivíduo é mostrada na Figura 5.4.

Variáveis Binárias																		
1	2	3	4	5	6	7	8	9	...	208	209	210	211	212	213	214	215	216
UHE1		UHE2		UHE3		UHE4			...	UHE1		UHE2		UHE3		UHE4		
0	1	0	1	1	0	0	1	0	...	0	1	0	1	0	1	1	1	0



 t=1
 t=24

Figura 5.4 – Exemplo da parcela binária de um indivíduo ou solução.

5.3.1.3 Representação da Solução Candidata

Os indivíduos e a população do problema são de característica híbrida ou mista (característica binária e real), cada a qual representada de forma isolada nas seções anteriores. A solução final será composta por uma parcela única contendo estas duas parcelas.

O total de variáveis necessárias para o problema de otimização está mostrado na Tabela 5.18. No cenário apresentado, em um total de vinte quatro intervalos de tempo, o total de variáveis será de trezentas e trinta e seis, sendo cento e vinte variáveis reais e duzentas e dezesseis variáveis binárias.

Tabela 5.18 – Representação mista das variáveis do problema por intervalo de tempo.

Usina	Variáveis binárias	Variáveis reais	Total
UHE1	2	1	3
UHE2	2	1	3
UHE3	2	1	3
UHE4	3	2	5
Total	9	5	14
24 intervalos	216	120	336

O exemplo de um indivíduo da população, que representa uma tentativa de solução terá a característica demonstrada na Figura 5.5.

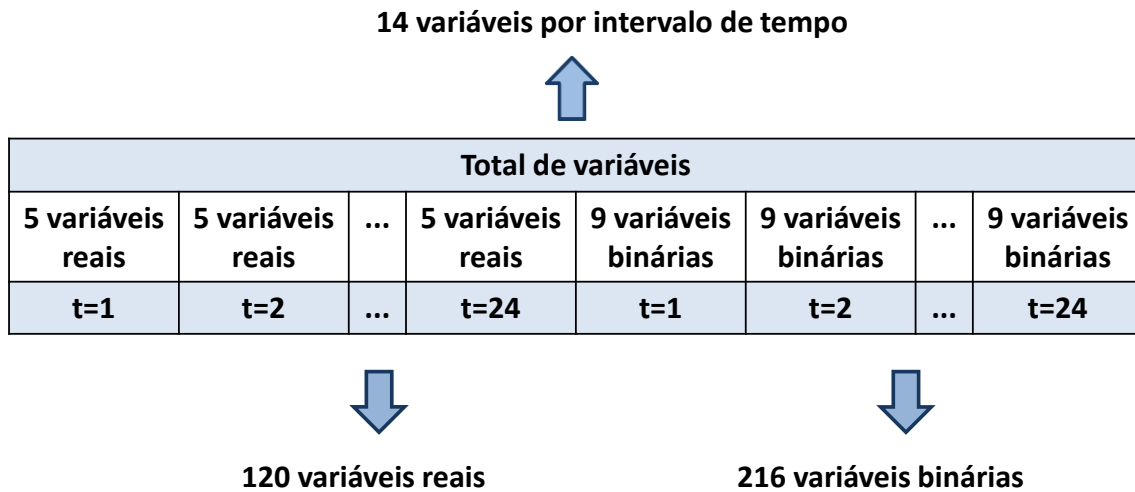


Figura 5.5 – Representação mista de um indivíduo ou solução.

5.3.2 Função Objetivo e Restrições

Cada indivíduo da população do método metaheurístico será uma solução a ser avaliada, de forma a determinar o quão boa ou ruim é esta tentativa de solução. Esta avaliação é feita pela função objetivo ou função avaliação. Para determinar se uma solução é boa ou ruim, deve-se avaliar simultaneamente o valor da função objetivo e o atendimento ou não às restrições do problema.

Uma das formas de incorporar as restrições do problema na avaliação das soluções é acrescentar o nível de violação das restrições na função objetivo, testando soluções viáveis e inviáveis igualmente, porém diferentemente penalizadas. Transforma-se assim o problema de otimização com espaço de busca restrito em um problema de otimização irrestrito. As restrições são incorporadas no valor da função objetivo, transformando a função dada pela Equação (3.21) na seguinte Equação:

$$\sum_{t=1}^T \sum_{r=1}^R Q_{rt} + s_{rt} + \sum_{j=1}^{nrt} \sigma 1_{jr} [u_{jrt}(1 - u_{jrt-1})] + \sigma 2_{jr} [u_{ij,t-1}(1 - u_{jrt})] + \sum_{k=1}^{Nk} \lambda_k (\alpha_k) \quad (5.1)$$

Sendo:

α_i : Violação da restrição i

λ_1 : Coeficiente de penalização para a restrição i

Nk : Número de restrições adotadas

A partir da abordagem proposta, soluções viáveis e inviáveis são diferenciadas somente pelo valor retornado pela função objetivo da Equação (5.1). Para isto, o peso das violações das restrições deve ser devidamente ajustado, de forma que gradativamente descartem-se soluções inviáveis em detrimento de soluções viáveis e que entre soluções inviáveis, priorizem-se as que possuem as menores penalidades e que violem as menores restrições. As restrições apresentadas na Seção 3.4.3 serão introduzidas da seguinte forma:

Violação da restrição de demanda:

$$\alpha_1 = \sum_{t=1}^T \begin{cases} L_t - Pg_t & , \text{ caso } L_t - Pg_t < 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.2)$$

Violação da restrição de vazão máxima:

$$\alpha_2 = \sum_{t=1}^T \begin{cases} q_{jt} - q_{jt}^{max} & , \text{ caso } q_{jt} - q_{jt}^{max} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.3)$$

Violação da restrição de vazão mínima:

$$\alpha_3 = \sum_{j=1}^{n_{rt}} \sum_{t=1}^T \begin{cases} q_{jt}^{min} - q_{jt} & , \text{ caso } q_{jt}^{min} - q_{jt} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.4)$$

Violação de restrição de potência máxima:

$$\alpha_4 = \sum_{t=1}^T \begin{cases} pg_{jt} - pg_{jt}^{max} & , \text{ caso } pg_{jt} - pg_{jt}^{max} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.5)$$

Violação de restrição de potência mínima:

$$\alpha_5 = \sum_{j=1}^{n_{rt}} \sum_{t=1}^T \begin{cases} pg_{jt}^{min} - pg_{jt} & , \text{ caso } pg_{jt}^{min} - pg_{jt} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.6)$$

Violação de restrição de volume mínimo

$$\alpha_6 = \sum_{r=1}^{n_{rt}} \sum_{t=1}^T \begin{cases} v_r^{min} - v_{rt} & , \text{ caso } v_r^{min} - v_{rt} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.7)$$

Violação de restrição de volume máximo

$$\alpha_7 = \sum_{r=1}^R \sum_{t=1}^T \begin{cases} v_{rt} - v_r^{max} & , \text{ caso } v_{rt} - v_r^{max} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.8)$$

Violação de restrição de defluência mínima

$$\alpha_8 = \sum_{r=1}^R \sum_{t=1}^T \begin{cases} U_r^{min} - (U_{rt}) & , \text{ caso } U_r^{min} - (U_{rt}) > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.9)$$

Violação de restrição de defluência máxima:

$$\alpha_9 = \sum_{r=1}^R \sum_{t=1}^T \begin{cases} U_r^{max} - (U_{rt}) & , \text{ caso } (U_{rt}) - U_r^{max} > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.10)$$

Limite de rampa de defluência

$$\alpha_{10} = \sum_{r=1}^R \sum_{t=1}^T \begin{cases} |(U_{r,t}) - (U_{r,t-1})| & , \text{ caso } |(U_{rt}) - U_r^{max}| > d_r^{max} \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.11)$$

Restrição de reserva girante mínima

$$\alpha_{11} = \sum_{t=1}^T \begin{cases} \sum_{r=1}^R \sum_{j=1}^{n_{rt}} pmax_{jrt} - pg_{jrt} & , \text{ caso } \left| \sum_{r=1}^R \sum_{j=1}^{n_{rt}} pmax_{jrt} - pg_{jrt} \right| > g_t \\ 0 & , \text{ caso contrário} \end{cases} \quad (5.12)$$

Pode-se observar que violações pequenas das restrições terão peso menor que violações elevadas ou múltiplas violações, facilitando ao método de otimização fugir de soluções não viáveis em direção a soluções viáveis. Desta forma, soluções que violam menos as restrições são priorizadas, sendo necessário definir o coeficiente de penalização de cada restrição. Restrições cujos coeficientes de penalização sejam maiores tendem a guiar o método de solução, tendo peso maior na solução, enquanto restrições com coeficientes de penalização menores tendem a ter menor impacto.

Os coeficientes de penalidades adotados neste trabalho foram os apresentados na Tabela 5.19, sendo escolhidos após extensivos testes.

Tabela 5.19 – Coeficientes de penalização adotados.

Coeficientes	Valor	Coeficiente	Valor
λ_1	1.000	λ_8	10.000
λ_2	100.000	λ_9	10.000
λ_3	100.000	λ_{10}	1.000
λ_4	10.000	λ_{11}	500
λ_5	10.000	σ_1	500
λ_6	1.000.000	σ_2	0
λ_7	1.000.000		

5.4 Simulações

Nesta seção serão apresentados os resultados para as simulações do problema de otimização da operação diária da geração hidrelétrica em cascata. Serão estudados os modelos propostos frente a diferentes cenários. As simulações realizadas neste trabalho foram desenvolvidas em ambiente Matlab© em computador pessoal: processador Intel Core i5, 3.00GHz e 8GB de RAM.

5.4.1 Ajuste dos Métodos

Nesta seção são apresentadas os ajustes de parametrização para o problema de otimização estudado. São mostrados os resultados da implementação de três métodos metaheurísticos: Enxame de Partículas Unificado (UPSO), Seção 5.4.1.1, Algoritmo Genético (AG), Seção 5.4.1.2, e Algoritmo de Evolução Diferencial (DE), Seção 5.4.1.3.

Os testes realizados foram feitos sobre o Sistema Teste, apresentado na Seção 5.2.1 no cenário de operação Cenário Base apresentado na Seção 5.2.2. Serão apresentados a seguir os melhores ajustes encontrados para os três métodos, de forma a apresentar soluções viáveis ao problema. Os tempos de simulação considerados adequados foram determinados de acordo com a possibilidade da utilização das soluções em cenários de otimização horários.

Os métodos foram implementados sobre funções avaliação, ou funções objetivo, e tratamento de restrições, conforme apresentado na Seção 5.3.2. Para cada método um número elevado de simulações foi realizado a fim de definir a eficiência e reprodutibilidade das soluções. Populações iniciais aleatórias foram iniciadas em todos os métodos. Os diferentes cenários de população e iterações avaliados e a quantidade de avaliações da função objetivo em cada uma estão presente na Tabela 5.20.

Tabela 5.20 - Número de avaliações da função objetivo por condição avaliada

Avaliações da Função Objetivo				
Pop/Iter	500	1000	2000	3000
50	25.000	50.000	100.000	150.000
100	50.000	100.000	200.000	300.000
200	100.000	200.000	400.000	600.000

5.4.1.1 Algoritmo de Enxame de Partículas Unificado (UPSO)

O método Enxame de Partículas Unificado (UPSO) com representação híbrida possui como parâmetros as constantes indicadas na Seção 4.2.5. Os parâmetros adotados neste trabalho estão presentes na Tabela 5.21.

Tabela 5.21 – Ajustes dos parâmetros do método UPSO

Parcela Real		Parcela Binária	
Parâmetro	Valor	Parâmetro	Valor
φ_1	0,72984	φ_3	0,72984
φ_2	0,72984	φ_4	0,72984
$\omega_r min$	0,55	$\omega_b min$	1,0
$\omega_r max$	0,90	$\omega_b max$	1,0
u	0,3	u	0,3
$v_r min$	$-\infty$	$v_b min$	-7
$v_r max$	∞	$v_b max$	7

Os coeficientes de inércia foram adotados variando a cada iteração, conforme apresentado na Equação (4.3), e as velocidades limitadas conforme a Equação (4.4). As topologias utilizadas foram a topologia em anel, com $k = 1$ e topologia global.

Foram feitas diferentes simulações com tamanho de população e número de iterações variado. O tamanho da população testado neste método foi de 50, 100 e 200 partículas. O número de iterações de 500 a 3000. Um total de dez simulações foi realizado em cada caso citado. As simulações foram feitas sobre o Cenário Base com formulação da função objetivo apresentada na Seção 5.3.2.

A quantidade de soluções viáveis encontrada em cada condição de população x iteração é mostrada na Tabela 5.22. Os valores médios da função objetivo e do tempo de simulação são mostrados na Tabela 5.23. A Tabela 5.24 mostra os melhores e piores resultados obtidos em cada condição. A Tabela 5.25 indica, entre as soluções viáveis, o custo médio obtido e o número médio de partidas.

Tabela 5.22 – Percentual de soluções viáveis e tempo de simulação em diferentes condições de população e iterações. (método UPSO)

Soluções com resultado viável (%)				
Pop/Iter	500	1000	2000	3000
50	0 %	80 %	90 %	100 %
100	60 %	100 %	100 %	100 %
200	100 %	100 %	100 %	100 %

Tabela 5.23 – Média do valor da função objetivo e variação média do valor das soluções em diferentes condições de população e iterações (método UPSO)

Função objetivo (m ³ /s)					Tempo de simulação (s)			
Pop/Iter	500	1000	2000	3000	500	1000	2000	3000
50	7,65e+06	1,22e+05	75.363	65.681	162,82	325,43	648,09	969,44
100	6,27e+05	66.895	65.079	63.462	288,41	571,75	1140,5	1610,8
200	68.215	65.918	63.685	62.908	498,48	995,61	2020,8	2921,9

Tabela 5.24 – Melhor e pior solução em cada condição (método UPSO)

Melhor solução (m ³ /s)					Pior solução (m ³ /s)			
Pop/Iter	500	1000	2000	3000	500	1000	2000	3000
50	3,81e+05	66.104	64.153	63.734	4,11e+07	5,98e+05	1,53e+05	67.853
100	68.266	64.786	63.573	62.271	3,77e+06	69.524	67.287	64.796
200	64.741	64.089	61.901	60.551	70.123	67.539	66.882	65.871

Tabela 5.25 – Custo médio e número médio de partidas de soluções viáveis (método UPSO)

Custo médio					Média de ligamentos de máquinas			
Pop/Iter	500	1000	2000	3000	500	1000	2000	3000
50	-	68.229	66.844	65.681	-	21,1	20,8	20
100	72.115	66.895	65.079	63.462	24	19,2	19,7	17,7
200	68.215	65.918	63.685	62.908	19,4	19,1	18,4	16,7

A Figura 5.6 indica a melhor solução encontrada pelo método UPSO condição de população = 200 e iterações =3000. O valor mínimo encontrado para a função objetivo foi de 60.551, cenário com 14 partidas totais de máquinas.




Figura 5.6 – Melhor solução encontrada pelo método UPSO.

A Tabela 5.26 mostra, neste cenário, a diferença total entre a demanda programada e a geração sugerida e o somatório da vazão defluente de todas as usinas, durante as 24 horas de simulação.

Tabela 5.26 – Resultados para a melhor solução encontrada pelo método UPSO.

Tempo	Erro demanda	(Q+s) (m ³ /s)	tempo	Erro demanda	(Q+s) (m ³ /s)
t=0	0,00 %	951,8	t=12	0,00 %	2588,2
t=1	0,00 %	1017,2	t=13	0,00 %	2426,3
t=2	0,00 %	1817,1	t=14	0,00 %	2773,6
t=3	0,00 %	2015,8	t=15	0,00 %	2260,6
t=4	0,00 %	2487,4	t=16	0,00 %	2733,0
t=5	0,00 %	2419,3	t=17	0,00 %	2458,8
t=6	0,00 %	2543,6	t=18	0,00 %	2339,9
t=7	0,00 %	2844,5	t=19	0,00 %	2466,5
t=8	0,00 %	2786,1	t=20	0,00 %	1695,1
t=9	0,00 %	3154,8	t=21	0,02 %	1190,8
t=10	0,00 %	3369,1	t=22	2,10 %	1058,6
t=11	0,00 %	3172,4	t=23	0,00 %	980,4

5.4.1.2 Algoritmo Genético

Para o método Algoritmo Genético especificam-se os operadores genéticos, conforme apresentado na Seção 4.3.4. Os operadores genéticos para o Algoritmo Genético, utilizados neste trabalho, estão indicados na Tabela 5.27.

Tabela 5.27 – Ajustes escolhidos para o método Algoritmo Genético

Operador Genético	
Seleção	Amostragem
Crossover	Uniforme
Mutação	Aritmética
Fator de Crossover	80%
Fator de Mutação	1%
Elitismo	5%

Em um total de dez simulações para cada cenário, foram simuladas otimizações com populações iguais a 50, 100 e 200. O número de iterações foi de 500, 1000, 2000 e 3000. Na Tabela 5.28 estão presentes os percentuais de soluções viáveis para cada cenário.

Tabela 5.28 – Percentual de soluções viáveis e tempo de simulação em diferentes condições de população e iterações. (método AG)

Soluções com resultado viável (%)				
Pop/Iter	500	1000	2000	3000
50	0 %	100 %	100 %	90 %
100	70 %	100 %	100 %	100 %
200	100 %	100 %	100 %	100 %

Na Tabela 5.29 está indicada a média do valor da função objetivo e o tempo médio de simulação em cenários idênticos. A Tabela 5.30 indica a melhor e pior solução encontradas por cada um dos métodos em cada cenário e a Tabela 5.31 indica o custo e o número de partidas médio, em soluções viáveis, retornado em cada condição.

Tabela 5.29 – Média do valor da função objetivo e variação média do valor das soluções em diferentes condições de população e iterações (método AG)

Função objetivo (m ³ /s)					Tempo de simulação (s)			
Pop/Iter	500	1000	2000	3000	500	1000	2000	3000
50	3,13e+06	69.135	65.992	1,59e+05	119,29	236,91	473,89	794,09
100	2,56e+05	66.933	66.008	65.347	256,15	509,1	952,92	1495,18
200	71.222	67.023	65.237	64.720	505,33	1075,6	2365,6	2962,2

Tabela 5.30 – Melhor e pior solução em cada condição (método AG)

Melhor Solução					Pior Solução			
Pop/Iter	500	1000	2000	3000	500	1000	2000	3000
50	1,04e+06	66.204	63.674	64.239	5.39e+06	71.716	68.117	9.92e+05
100	74.084	64.863	62.574	63.324	1.55e+06	68.441	68.345	67.870
200	68.056	64.228	61.680	61.595	74.967	71.708	67.994	69.359

Tabela 5.31 – Custo médio e número médio de partidas nas soluções viáveis de cada cenário. (método AG)

Custo médio					Média de ligamentos de máquinas			
Pop/Iter	500	1000	2000	3000	500	1000	2000	3000
50	-	69.135	65.992	67.942	-	23,4	21,9	24,7
100	79.524	66.933	66.008	65.347	36,7	22,9	22,3	21,5
200	71.222	67.023	65.237	64.720	25,7	24,6	21,8	20,2

A melhor solução encontrada nas simulações para pop=200 iterações =3000 está mostrada na Figura 5.7, onde são mostradas as potências despachadas por cada unidade geradora e a curva de demanda do sistema. O valor total da função objetivo foi de 61.595 e o total de partidas foi igual a 18.




Figura 5.7 – Melhor solução encontrada pelo método AG.

Na melhor solução obtida, os valores de erro na demanda, e vazão defluente total, por intervalo de tempo estão presentes na Tabela 5.32.

Tabela 5.32 - Resultados para a melhor solução encontrada pelo método AG.

Intervalo de tempo	Erro demanda (%)	(Q+s) (m ³ /s)	Intervalo de tempo	Erro demanda (%)	(Q+s) (m ³ /s)
t=0	0,22 %	946,2	t=12	0,00 %	2542,8
t=1	0,07 %	1123,1	t=13	0,01 %	2265,3
t=2	0,00 %	1880,9	t=14	0,01 %	2583,9
t=3	0,03 %	2100,0	t=15	1,43 %	2136,83
t=4	0,05 %	2410,3	t=16	0,02 %	2548,5
t=5	0,02 %	2330,8	t=17	0,03 %	2216,0
t=6	0,01 %	2598,1	t=18	0,03 %	2146,9
t=7	0,02 %	2841,4	t=19	0,08 %	2281,6
t=8	0,01 %	2756,0	t=20	0,05 %	1766,2
t=9	0,01 %	3156,6	t=21	0,07 %	1417,2
t=10	0,00 %	3355,1	t=22	0,17 %	1051,9
t=11	0,00 %	3084,1	t=23	0,64 %	1055,1

5.4.1.3 Algoritmo de Evolução Diferencial

Seguindo a abordagem proposta em [24] e detalhada na Seção 4.4.2 os seguintes parâmetros foram adotados, para o método de Evolução Diferencial:

Tabela 5.33 – Ajustes iniciais escolhidos para o método Evolução Diferencial

Parâmetros Método DE	
μ	4
$F(0)$	1
$CR(0)$	1

A evolução dos coeficientes de mutação e de *crossover* será feita a cada iteração conforme apresentado anteriormente nas Equações (4.26) e (4.27).

$$F(G) = \mu \cdot F(G - 1) \cdot [1 - F(G - 1)]$$

$$CR(G) = \mu \cdot CR(G - 1) \cdot [1 - CR(G - 1)]$$

As populações consideradas foram: 50, 100 e 200 indivíduos. Os números de iterações considerados foram: 500, 1000, 2000 e 3000. A porcentagem de soluções viáveis encontradas, no total de dez simulações para cada condição, é indicada na Tabela 5.34, onde estão presentes também os respectivos tempos de simulação.

Tabela 5.34 – Percentual de soluções viáveis e tempo de simulação em diferentes condições de população e iterações. (método DE)

Soluções com resultado viável (%)				
Pop/Iter	500	1000	2000	3000
50	0 %	10 %	10 %	10 %
100	30 %	100 %	100 %	90 %
200	50 %	100 %	100 %	100 %

O valor médio da função objetivo e também a variação média entre os valores das soluções estão presentes na Tabela 5.35.

Tabela 5.35 – Média do valor da função objetivo e tempo de simulação em diferentes condições de população e iterações (método DE)

Pop/Iter	Função objetivo (m ³ /s)				Tempo de simulação (s)			
	500	1000	2000	3000	500	1000	2000	3000
50	8,92e+06	4,06e+06	2,57e+06	2,38e+06	118,92	249,51	490,21	731,17
100	9,28e+05	70,710	67,145	1,78e+05	242,31	487,57	974,54	1457,8
200	2,05e+05	68.846	63.040	62.984	487,64	976,33	1959,7	2928,5

A melhor e a pior solução de cada cenário estão mostradas na Tabela 5.36.

Tabela 5.36 – Melhor e pior solução em cada condição (método DE)

Pop/Iter	Melhor solução				Pior solução			
	500	1000	2000	3000	500	1000	2000	3000
50	3,86e+06	84.365	74.948	71.127	1.73e+07	1,03e+07	8,67e+06	6,42e+06
100	84.443	68.129	64.644	63.662	3.49e+06	73.147	70.559	1,18e+06
200	82.029	65.959	61.789	61.753	5.13e+05	70.575	64.645	64.383

Considerando as soluções viáveis, foram determinados o valor médio da função objetivo e o valor médio do número de partidas de unidades geradoras, presentes na Tabela 5.37.

Tabela 5.37 – Custo médio e número médio de partidas nas soluções viáveis de cada cenário. (método DE)

Pop/Iter	Custo médio				Média de ligamentos de máquinas			
	500	1000	2000	3000	500	1000	2000	3000
50	-	84.365	74.948	71.127	-	44,6	35,4	36,2
100	85.087	70.710	67.145	67.221	42	24,2	23,6	23,5
200	92.328	68.846	63.040	62.984	38,3	19,6	17,3	18,0

A melhor solução encontrada pelo método de Evolução Diferencial teve valor de 61.753 e um total de 16 partidas. A característica de potência por unidade geradora da solução está mostrada na Figura 5.8.




Figura 5.8 – Melhor solução encontrada pelo método DE.

A Tabela 5.38 mostra a diferença percentual entre a geração e a demanda programada, além do somatório total de vazão turbinada e vertida em todas as usinas, por intervalo de tempo.

Tabela 5.38 – Resultados para a melhor solução encontrada pelo método DE.

Intervalo de tempo	Erro demanda (%)	(Q+s) (m ³ /s)	Intervalo de tempo	Erro demanda (%)	(Q+s) (m ³ /s)
t=0	0,07 %	1088,3	t=12	0,02 %	2559,3
t=1	5,55 %	1252,5	t=13	0,01 %	2366,2
t=2	0,06 %	1981,9	t=14	0,00 %	2607,3
t=3	0,08 %	2113,4	t=15	0,10 %	2101,7
t=4	0,04 %	2429,7	t=16	0,04 %	2708,4
t=5	0,08 %	2425,1	t=17	0,10 %	2415,0
t=6	0,05 %	2622,7	t=18	0,03 %	2328,8
t=7	0,05 %	2918,1	t=19	0,03 %	2423,1
t=8	0,05 %	2832,9	t=20	0,22 %	1760,9
t=9	0,01 %	3195,0	t=21	0,10 %	1270,8
t=10	0,01 %	3421,1	t=22	15,40 %	936,9
t=11	0,10 %	3122,1	t=23	0,13 %	871,8

5.4.2 Comparação entre Métodos

Os três métodos apresentados resolveram o problema modelado sobre a mesma função objetivo sobre os mesmos tipos de restrições, mesmas condições e limites de operação. Os números de variáveis utilizadas no problema foram os mesmos, em um total de 336 variáveis. A parametrização de cada método foi feita de acordo com testes do mesmo sistema base o que permite uma avaliação dos métodos de solução sobre as mesmas condições.

Diferenças quanto à abordagem das variáveis em cada método foram adotadas. No método UPSO e AG adotou-se uma abordagem híbrida, variáveis reais e variáveis binárias, pois se observou que a modelagem aqui apresentada atendeu de forma satisfatória ao problema. Um total de 120 variáveis reais e 216 variáveis binárias foi utilizado. Os métodos de Evolução Diferencial utilizou o mesmo número de variáveis, porém tratando as variáveis binárias como variáveis reais limitadas na faixa [0,1] arredondadas para o respectivo inteiro mais próximo. A diferença de abordagem se tornou necessária, pois os operadores de mutação destes dois métodos fazem com que o mesmo consiga alterar a parcela respectiva aos termos binários sem perder desempenho. Já o método UPSO possui pouca capacidade de mutação e alterações bruscas de status, o que impediu uma abordagem puramente real neste tipo de problema. Abordagens híbridas para os métodos de Evolução Diferencial foram testadas, porém não apresentaram desempenho satisfatório, não sendo apresentadas neste trabalho.

O melhor resultado encontrado por cada método está listado na Tabela 5.39. Os melhores resultados encontrados foram obtidos na condição de maior população e maior número de iterações.

Tabela 5.39 – Melhor solução encontrada por cada método metaheurístico.

Método	Pop	Iter	função objetivo	Tempo (s)	Nº de partidas
UPSO	200	3000	60.551	2921,9	14
AG	200	3000	61.595	2962,2	18
DE	200	3000	61.753	2923,0	16

Uma análise de desempenho dos métodos conforme a faixa de população e iterações está presente a seguir. Na Tabela 5.40 está mostrado o desempenho médio das soluções viáveis para uma população de 50 indivíduos. O método UPSO foi o que obteve menor valor médio da função objetivo, seguido pelo método AG e DE. Os métodos UPSO e AG encontraram soluções viáveis ao problema em uma proporção alta de testes, já o método DE não conseguiu um desempenho satisfatório, obtendo soluções viáveis em uma parcela pequenas das soluções. O valor médio da função objetivo pelo método DE foi também alto, se comprado aos demais métodos.

Tabela 5.40 – Desempenho médio das soluções viáveis: pop=50; 1000 ≤ iter ≤ 3000

Método	Custo médio das soluções viáveis	Número médio de ligamentos	Proporção de testes com solução viável
UPSO	66.918	20,63	90 %
AG	67.690	23,33	96,7 %
DE	76.813	38,73	10 %

Para uma população igual a 100 indivíduos, os métodos apresentaram uma proporção alta de soluções viáveis, estando novamente o método UPSO com desempenho superior. Os resultados estão presentes na Tabela 5.43.

Tabela 5.41 – Desempenho médio das soluções viáveis : pop=100; 1000 ≤ iter ≤ 3000

Método	Custo médio das soluções viáveis	Número médio de ligamentos	Proporção de testes com solução viável
UPSO	65.145	18,87	100 %
AG	66.096	22,23	100 %
DE	68.359	23,77	96,7 %

Para um número elevado de indivíduos e de iterações (pop=200, iter>2000), o método que obteve melhor desempenho foi o método DE. Os três métodos obtiveram soluções viáveis em todas as soluções, sendo o menor custo médio obtido pelos métodos DE, UPSO e AG nessa ordem. O desempenho médio dos métodos nesta condição está presente na Tabela 5.44. Nesta condição, o método UPSO alcançou, em média, um número de partidas de máquinas inferior aos demais métodos testados.

Tabela 5.42 – Desempenho médio das soluções viáveis : pop=200; 2000 ≤ iter ≤ 3000

Método	Custo médio das soluções viáveis	Número médio de ligamentos	Proporção de testes com solução viável
UPSO	63.297	17,55	100 %
AG	64.979	21	100 %
DE	63.012	18,3	100 %

Como resultado das simulações pode-se observar que os métodos UPSO e AG conseguem atingir soluções viáveis para o problema com menor número de iterações e conseguem resolver o problema com populações reduzidas. O método de Evolução Diferencial apresentou soluções com valores de função objetivo médios inferiores aos demais métodos, porém sobre o custo de um número elevado de avaliações da função objetivo.

Para observar o desempenho dos métodos ao longo das iterações, foi monitorado o valor da função objetivo, a quantidade total de água utilizada e o número total de partidas de unidades geradoras da melhor solução encontrada por cada método. Tais dados estão presentes respectivamente na Figura 5.9, Figura 5.10 e Figura 5.11. As simulações realizadas foram feitas para uma população = 200 para os métodos UPSO, DE e AG. Um total de 2000 iterações foi considerado em todas as simulações.




Figura 5.9 – Evolução do valor da função objetivo de uma solução de cada método.

Pode-se observar que a evolução da solução do método começa a partir de soluções com alto valor de função objetivo, devido a violação de diferentes penalidades, até chegar a um patamar mais reduzido, violando um número cada vez menor de restrições até atingir soluções viáveis.




Figura 5.10 – Evolução do valor da vazão total da de uma solução de cada método.




Figura 5.11 - Evolução do número de partidas de uma solução de cada método.

O número de partidas, assim como a condição inicial de vazão, começa de soluções aleatórias, buscando soluções que não violem as restrições do problema até buscar a minimização da quantidade de partidas propriamente dita.

O valor da vazão total do sistema parte de patamares aleatórios até atingir valores que atendam as principais restrições do sistema, como atendimento a carga e vazão mínima. Atendendo às restrições do problema, o valor da vazão diminui de forma a reduzir o valor da função objetivo. O valor elevado atribuído às restrições faz com que as iterações iniciais sejam de correção das violações e as iterações finais tratem da minimização da utilização da água.

5.4.3 Cenários Avaliados

Nesta seção serão apresentados os resultados dos métodos de otimização frente a diferentes cenários de operação de forma a avaliar a eficiência dos métodos. Nos cenários avaliados foram propostas diferentes condições de: níveis de vazão e volume nos reservatórios, demanda ao longo do dia e limitação do número de partidas e paradas.

Os resultados foram obtidos através das três metaheurísticas apresentadas. O período de simulação em todos os casos considerados foi de vinte e quatro horas, com discretização horária.

5.4.3.1 Variação de Afluências e Volume

Quatro diferentes condições de vazão e volume foram analisadas neste trabalho. Em todos estes casos, a condição de demanda adotada foi igual à do Caso Base. Para cada caso serão realizadas três simulações, uma para cada método: UPSO, AG e DE.

Foram considerados dois casos com volume dos reservatórios baixo e vazão afluente baixa (aqui considerada hipoteticamente nula). O primeiro cenário considerado, Cenário 1, é mostrado na Tabela 5.43.

Tabela 5.43 – Cenário alternativo de volume e vazão incremental – Cenário 1.

Cenário 1				
Operação	UHE1	UHE2	UHE3	UHE4
Volume útil (%)	15	15	15	15
Vazão incremental (m ³ /s)	0	0	0	0

Frente à mudança do cenário de volume e vazão, foi avaliado o desempenho dos três métodos citados neste trabalho. Os resultados obtidos para a função objetivo e para o volume final de cada reservatório estão mostrados na Tabela 5.44.

Tabela 5.44 – Resultados para o Cenário 1 de vazão e volume inicial

Método	Função Objetivo	(Q+s) (m ³ /s)	Número de partidas	Volume Final (%)			
				UHE1	UHE2	UHE3	UHE4
UPSO	69.368	59.868	19	0,56 %	13,48 %	14,81 %	10,13 %
AG	66.551	58.551	16	1,33 %	13,45 %	14,51 %	11,20 %
DE	67.555	59.555	16	1,55 %	13,74 %	13,08 %	12,12 %

Os resultados obtidos para o Cenário 1 mostram que os três métodos obtêm uma solução viável nesta condição de operação. Pode-se observar que os valores da função objetivo retornados pelos três métodos apresentam valores próximos, mesmo para diferentes tipos de soluções. Para o cenário 1, a solução obtida pelo método UPSO, método AG e método DE estão presentes na Figura 5.12, Figura 5.13 e Figura 5.14 respectivamente.




Figura 5.12 - Solução pelo método UPSO, Cenário 1 .




Figura 5.13 - Solução pelo método AG, Cenário 1 .

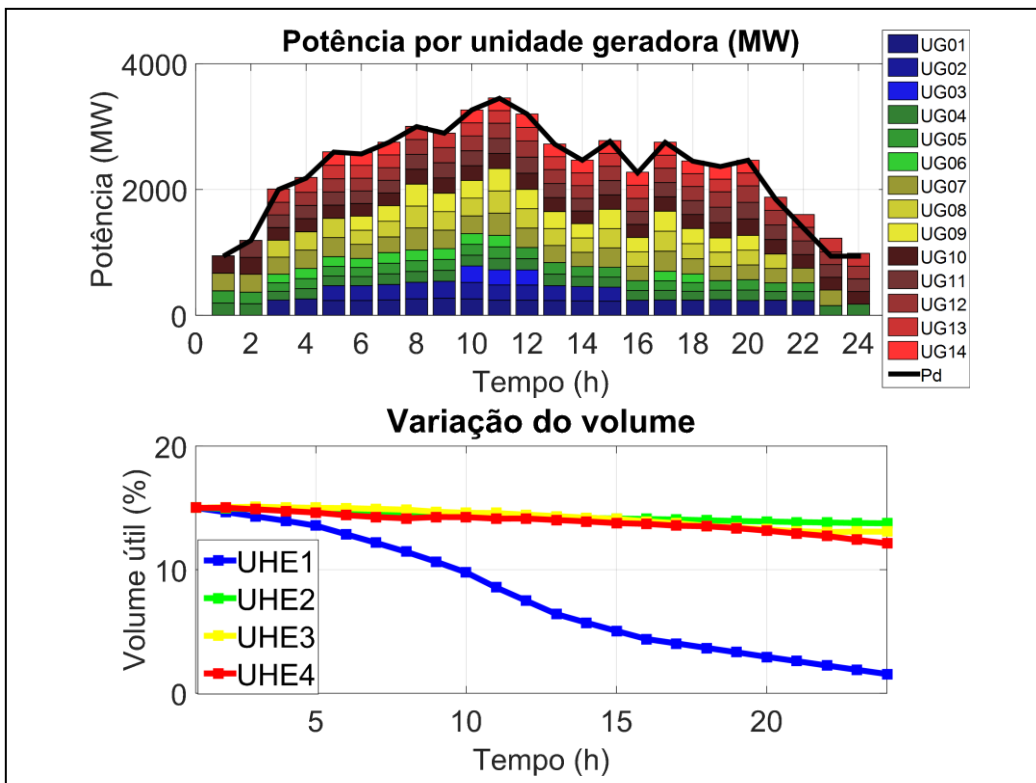


Figura 5.14 – Solução pelo método DE, Cenário 1.

Os resultados obtidos neste cenário indicam que a demanda programada para este dia de operação forçam uma utilização quase que completa do volume útil da usina hidrelétrica UHE1. Todas as restrições, porém, são atendidas nesta condição de operação, sendo todo o volume útil considerado para a geração. Para evitar a utilização completa do mesmo, pode-se também adotar limites maiores para este reservatório, o que não foi adotado neste trabalho.

Em um segundo cenário, foi variado o volume inicial e a vazão incremental em cada usina para os mostrados na Tabela 5.45.

Tabela 5.45 – Cenário alternativo de volume e vazão incremental – Cenário 2.

Cenário 2				
Volume útil (%)	UHE1	UHE2	UHE3	UHE4
Volume inicial (hm ³)	30	30	30	30
Vazão incremental (m ³ /s)	0	0	0	0

O Cenário 2 foi simulado pelos métodos de otimização, estando os resultados presentes na Tabela 5.46.

Tabela 5.46 – Resultados para o Cenário 2 de vazão e volume inicial

Método	Função Objetivo	(Q+s) (m ³ /s)	Número de partidas	Volume Final (%)			
				UHE1	UHE2	UHE3	UHE4
UPSO	63.659	56.159	15	7,91 %	28,70 %	31,10 %	25,95 %
AG	65.972	55.972	20	8,36 %	28,54 %	31,77 %	25,32 %
DE	66.489	55.989	21	7,39 %	28,74 %	31,28 %	25,57 %

Na Figura 5.18 está mostrada a solução encontrada pelo método UPSO, na Figura 5.19 está mostrada a solução encontrada pelo método AG e na Figura 5.20 está mostrada a solução encontrada pelo método DE.




Figura 5.15 - Solução pelo método UPSO, Cenário 2 .




Figura 5.16 - Solução pelo método AG, Cenário 2 .




Figura 5.17 - Solução pelo método DE, Cenário 2

Nos próximos dois cenários simulados serão considerados reservatórios com volume inicial alto e vazão afluente alta. O terceiro cenário de vazão e volume, Cenário 3, terá as condições apresentadas na Tabela 5.47.

Tabela 5.47 – Cenário alternativo de volume e vazão incremental – Cenário 3.

Cenário 3				
Operação	UHE1	UHE2	UHE3	UHE4
Volume útil (%)	75	75	75	75
Vazão incremental (m ³ /s)	559	463	475	669

Os resultados da simulação para os três métodos no Cenário 3 estão presentes na Tabela 5.48.

Tabela 5.48 – Resultados para o Cenário 3 de vazão e volume inicial

Método	Função Objetivo	(Q+s) (m³/s)	Número de partidas	Volume Final (%)			
				UHE1	UHE2	UHE3	UHE4
UPSO	62.721	54.221	17	82,33 %	75,19 %	81,61 %	76,07%
AG	60.840	50.840	20	82,10 %	75,19 %	81,07 %	79,11 %
DE	62.159	53.659	17	83,44 %	75,99 %	79,39 %	78,29 %

Os três métodos testados apresentaram soluções viáveis para esta condição de operação, com valores de Função Objetivo próximos. As soluções encontradas pelos métodos UPSO, AG e DE estão presentes respectivamente nas Figura 5.18, Figura 5.19 e Figura 5.20.

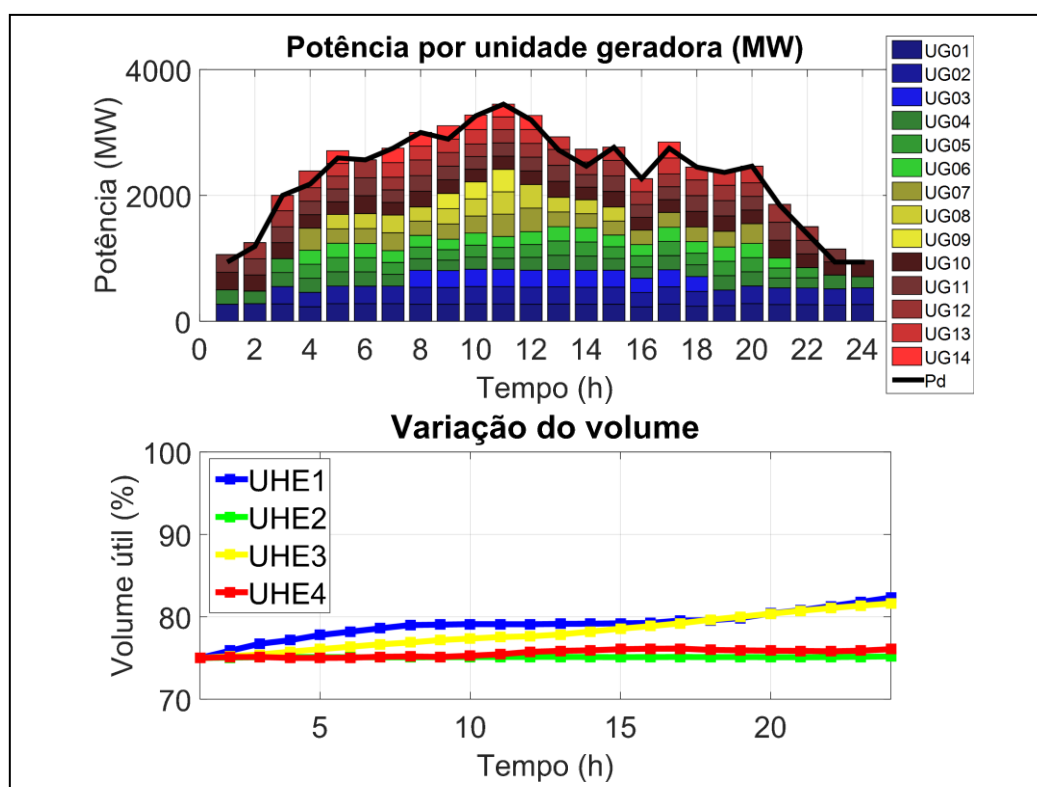


Figura 5.18 - Solução pelo método UPSO, Cenário 3 .




Figura 5.19 - Solução pelo método AG, Cenário 3 .




Figura 5.20 - Solução 1 pelo método DE, Cenário 3 .

Por último, no Cenário 4, foi representado um cenário com reservatórios com nível inicial e afluições altos. As condições iniciais de volume e afluição ao longo do dia estão mostradas na Tabela 5.49.

Tabela 5.49 – Cenário alternativo de volume e vazão incremental – Cenário 4.

Cenário 4				
Operação	UHE1	UHE2	UHE3	UHE4
Volume útil (% ³)	95	95	95	95
Vazão incremental (m ³ /s)	559	463	475	669

Os resultados encontrados pelas três metaheurísticas aplicadas ao Cenário 4 são mostrados na Tabela 5.50.

Tabela 5.50 – Resultados para o Cenário 4 de vazão e volume inicial

Método	Função Objetivo	(Q+s) (m ³ /s)	Número de partidas	Volume Final (%)			
				UHE1	UHE2	UHE3	UHE4
UPSO	62.255	54.755	21	100 %	95,62 %	99,70 %	98,86 %
AG	67.530	59.530	16	99,94 %	95,30 %	100 %	98,92 %
DE	62.559	55.059	15	100 %	95,73 %	99,28 %	99,15 %

A solução presente na Figura 5.21 indica a solução encontrada pelo método UPSO, a Figura 5.22 indica a solução encontrada pelo método AG e a Figura 5.23 indica a solução encontrada pelo método DE.

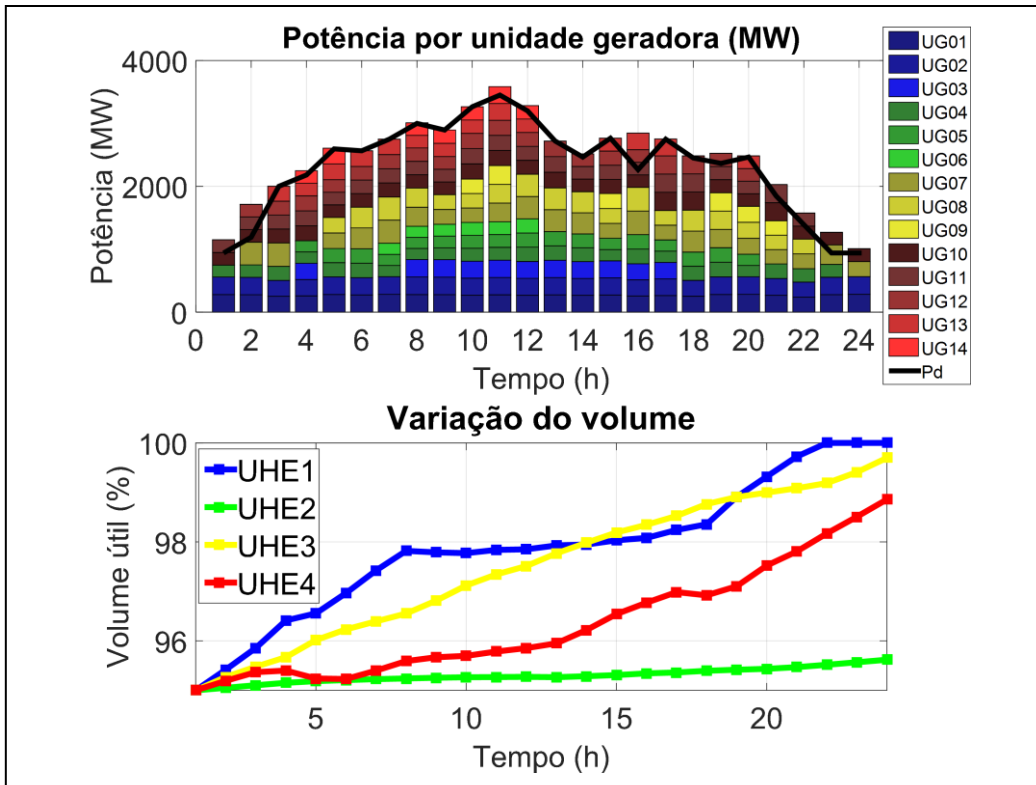


Figura 5.21 - Solução pelo método UPSO, Cenário 4

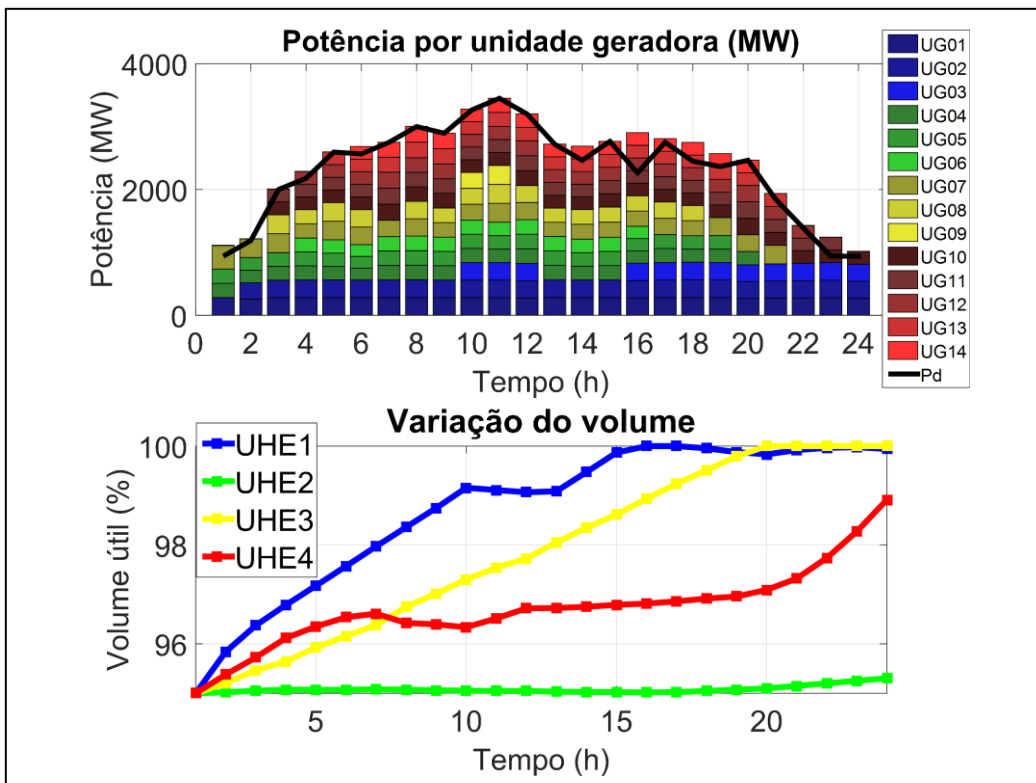


Figura 5.22 - Solução pelo método AG, Cenário 4




Figura 5.23 - Solução pelo método DE, Cenário 4

Os métodos avaliados atingiram condições de operação otimizadas em todas as simulações realizadas, mostrando a eficácia dos métodos em encontrar pontos ótimos de operação. Pode-se observar que a quantidade de água utilizada varia com o tipo de cenário analisado e com a disponibilidade de recursos hídricos e varia entre cada solução otimizada encontrada.

5.4.3.2 Variação da Curva de Demanda

Serão considerados também dois diferentes cenários de demanda ao longo do dia. Nestes dois cenários, as condições de vazão afluente e volume foram consideradas idênticas às do Caso Base. Como diferenciação do Caso Base serão propostas outras duas curvas de demanda com dois e três picos de demanda durante o dia.

A Tabela 5.51 mostra os valores de demanda ao longo das 24 horas para a segunda condição de demanda proposta, denominada Cenário 5, e a Figura 5.24 mostra a curva de demanda respectiva a estes dados.

Tabela 5.51 – Curva de Demanda – Cenário 5.

Tempo (h)	t=1	t=2	t=3	t=4	t=5	t=6	t=7	t=8	t=9	t=10	t=11	t=12
Demanda (MW)	940	2000	2595	3000	3265	3200	2720	2465	2265	1845	1390	1845
Tempo (h)	t=13	t=14	t=15	t=16	t=17	t=18	t=19	t=20	t=21	t=22	t=23	t=24
Demanda (MW)	2180	2565	2750	3450	3200	2750	2450	2365	2000	1845	1390	940




Figura 5.24 – Curva de Demanda – Cenário 5.

Os três métodos metaheurísticos apresentados foram utilizados para a solução do sistema nesta condição de demanda. Os valores da função objetivo e da vazão turbinada encontrada por cada método estão presentes na Tabela 5.52.

Tabela 5.52 – Resultados para o Cenário 5

Método	Função Objetivo	Vazão turbinada (m ³ /s)	Partidas
UPSO	64.494	53.994	21
AG	66.457	53.957	25
DE	64.143	53.643	21




Figura 5.25 - Solução pelo método UPSO, Cenário 5.




Figura 5.26 - Solução pelo método AG, Cenário 5.




Figura 5.27 - Solução pelo método DE, Cenário 5.

Na Tabela 5.53 estão mostrados os dados de demanda para a terceira condição de demanda proposta, que será denominada Cenário 6. A respectiva curva de demanda está apresentada na Figura 5.28.

Tabela 5.53 – Curva de Demanda – Cenário 6.

Tempo (h)	t=1	t=2	t=3	t=4	t=5	t=6	t=7	t=8	t=9	t=10	t=11	t=12
Demanda (MW)	940	2595	3265	2720	2265	1845	1845	2180	2750	3450	3800	3250
Tempo (h)	t=13	t=14	t=15	t=16	t=17	t=18	t=19	t=20	t=21	t=22	t=23	t=24
Demanda (MW)	2450	2365	2000	1845	1390	2000	2565	3000	3200	2465	1390	940




Figura 5.28 – Curva de Demanda – Cenário 6.

Os resultados obtidos pelos métodos de otimização neste cenário estão presentes na Tabela 5.54.

Tabela 5.54 – Resultados para o Cenário 6

Método	Função Objetivo	Vazão turbinada (m ³ /s)	Partidas
UPSO	67.935	55.935	24
AG	69.852	55.352	29
DE	68.258	57.528	22




Figura 5.29 - Solução pelo método UPSO, Cenário 6.




Figura 5.30 - Solução pelo método AG, Cenário 6.




Figura 5.31 - Solução pelo método DE, Cenário 6.

Os métodos metaheurísticos retornaram em cada cenário valores de função objetivo próximos, com faixas próximas no valor do somatório de vazões e número de partidas de máquinas. Todos os métodos simulados apresentaram resultados viáveis, demonstrando a eficiência dos métodos em encontrar soluções otimizadas frente à variação da demanda do sistema.

5.4.3.3 Limitação do Número de Partidas e Paradas

Para restringir o número de partidas e paradas diárias que as soluções propõem, foi considerado como restrição do problema um número máximo diário de ligamentos e desligamentos de unidades geradoras. A abordagem aqui realizada impede o ligamento de uma unidade geradora após a mesma já ter sido partida o número de vezes determinado pela respectiva restrição. O mesmo acontece para o desligamento de uma unidade, após a parada de uma unidade a mesma não poderá ser desligada até o fim do período de simulação.

As limitações adotadas são feitas a partir do instante inicial até o instante final, impedindo uma transição em um instante de tempo posterior ao instante em que máximo de transições é excedido.

No primeiro caso aqui simulado, limitou-se o número de partidas diárias a uma única partida por máquina. Os resultados da simulação estão presentes na Tabela 5.55.

Tabela 5.55 – Resultados para limitação de uma partida diária por máquina.

Método UPSO		Método AG		Método DE	
Partidas	$Q_{total} + S_{total}$ (m ³ /s)	Partidas	$Q_{total} + S_{total}$ (m ³ /s)	Partidas	$Q_{total} + S_{total}$ (m ³ /s)
13	56.061	14	55.063	14	56.155




Figura 5.32 – Método UPSO – Número de partida diária de cada máquina limitado




Figura 5.33 – Método AG – Número de partida diária de cada máquina limitado




Figura 5.34 – Método DE – Número de partida diária de cada máquina limitado

Observa-se que limitando a quantidade de partidas diárias consegue-se estabelecer uma quantidade máxima por máquina ao longo do dia encontrando-se novamente soluções viáveis ao problema.

No segundo caso simulado, impediu-se a parada de qualquer máquina ao longo do dia após a decisão de partida da mesma ser tomada. Os resultados estão indicados na Tabela 5.56.

Tabela 5.56 – Resultados para cenário sem paradas de máquinas.

Método UPSO		Método AG		Método DE	
Partidas	$Q_{total} + S_{total}$ (m ³ /s)	Partidas	$Q_{total} + S_{total}$ (m ³ /s)	Partidas	$Q_{total} + S_{total}$ (m ³ /s)
14	63.464	14	61.149	13	58.376




Figura 5.35 – Método UPSO – Impedimento de paradas de máquinas.

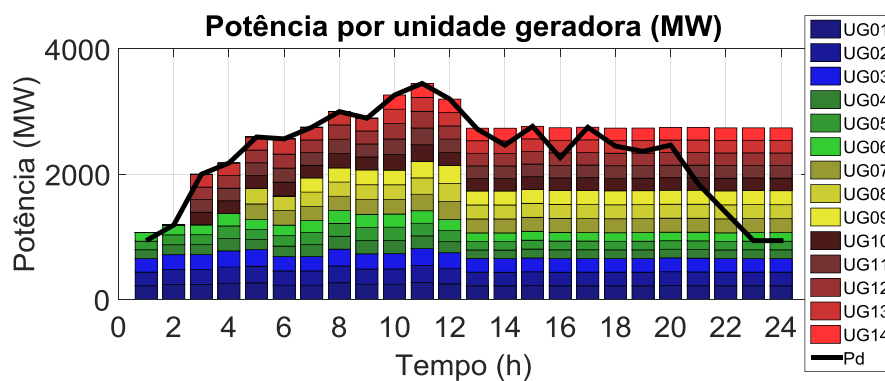


Figura 5.36 - Método AG – Impedimento de paradas de máquinas.




Figura 5.37 - Método DE – Impedimento de paradas de máquinas.

Tendo a penalidade de atendimento à demanda peso elevado, o ligamento de várias máquinas é realizado de forma a no mínimo atender a demanda do sistema. Estando o número de paradas de máquinas limitado, as máquinas ligadas tendem a gerar valores de potência mínimos em cenários onde a demanda é atendida com folga. O método de Evolução diferencial neste cenário apresentou um desempenho superior, tendo em sua solução um número de partidas de máquinas inferior às demais soluções.

Como a restrição de atendimento à carga adotada foi a de minimamente atender aos valores da demanda, as soluções encontradas possuem como resposta um valor de geração superior a da curva de demanda nos instantes finais, de forma que as máquinas já despachadas continuem gerando, mesmo que para isso despachem sua geração mínima.

Nas soluções encontradas, a operadora de geração irá despachar energia acima da demanda programada. Deve-se, portanto, analisar se tal solução é economicamente vantajosa ou não, pois, cabe à operação decidir se o menor número de transições é compensado pelo maior gasto de recursos energéticos e pela respectiva compensação financeira de tal operação.

CAPÍTULO 6

CONCLUSÕES

Este trabalho teve como objetivo desenvolver um modelo de otimização para a programação diária de um conjunto de usinas hidrelétricas em cascata. A otimização é feita através de métodos metaheurísticos, que são métodos de busca de condições ótimas aplicáveis a problemas de difícil solução. A programação diária da geração é uma das etapas do problema de planejamento da operação do sistema elétrico. A operação diária atua com base nos resultados do planejamento das etapas de longo, médio e curto prazo.

No problema de otimização da programação da geração diária, recorre-se a uma modelagem detalhada a nível de unidades geradoras, adotando as principais restrições e limites operativos do problema. O problema é dividido em duas etapas: o problema de alocação de unidades geradoras e o problema de despacho econômico. A primeira etapa visa estipular e reduzir o número de despachos de diferentes máquinas ao longo do dia, já a segunda visa definir o despacho ótimo do sistema, de forma a reduzir a utilização de recursos hídricos.

O caso estudado foi composto de um sistema de 4 usinas hidrelétricas, em um total de 14 unidades geradoras. Além do problema energético foi abordado conjuntamente o problema da operação dos reservatórios. A modelagem do sistema foi feita de forma detalhada, com definição de: curvas de eficiência das máquinas, polinômios para o nível dos reservatórios, limites operativos individuais das máquinas e das usinas.

Na solução abordada neste trabalho, o problema foi tratado como um problema de otimização inteiro-misto, com variáveis binárias para a representação da alocação de unidades e variáveis reais para o problema do despacho energético por máquina. Enquanto as variáveis binárias indicam o número de unidades despachadas de cada usina por intervalo de tempo, as variáveis reais indicam a vazão turbinada por unidade despachada por intervalo de tempo. O problema abordado possui um total de 336 variáveis, sendo 120 variáveis reais e 216 variáveis binárias.

Foram estudados três métodos para o problema de otimização inteiro-misto. Entre esses métodos estão: Otimização por Enxame de Partículas Unificado (UPSO), Algoritmo Genético (AG) e Evolução Diferencial (DE). Os três métodos apresentados se mostraram eficientes na solução de problemas com a característica necessária para este problema. Comparativamente, os métodos metaheurísticos apresentaram resultados próximos em valores de função objetivo em cada simulação. As calibrações dos métodos foram feitas frente a extensivos testes, sendo neste trabalho especificadas as parametrizações de cada método que apresentaram os melhores perfis de solução.

Foram avaliados diferentes cenários para variação de volume inicial dos reservatórios, carga demandada ao longo das 24 horas e restrição quanto ao número de partidas. Os métodos apresentados conseguiram encontrar soluções viáveis otimizadas em todos os casos apresentados, mostrando a eficiência da solução frente à variação das condições operativas do sistema.

Comparativamente, os três métodos obtiveram valores próximos para a função objetivo. Considerando somente a melhor solução encontrada, o método UPSO obteve o menor valor da função objetivo em todas as simulações. Já considerando a média do valor da função objetivo, para um tamanho de população e número de iterações devidamente elevado, o método DE foi o que obteve menor valor médio.

A metodologia de solução apresentada se mostra eficiente para solucionar problemas com características semelhantes. Este trabalho visa proporcionar uma abordagem de solução a ser reproduzida em problemas de mesma característica, com determinação da alocação de unidades geradoras e determinação do despacho das unidades. Os resultados obtidos neste trabalho visam, portanto, a utilização de tais técnicas e métodos para a realização da programação diária ótima em ambiente operacional.

6.1 Trabalhos Futuros

Como sugestão para trabalhos futuros, sugere-se a reprodução dos métodos para problemas de maior porte, aumentando-se o número de usinas e unidades. Sugere-se também avaliar novas restrições de operação, incluindo também as restrições de natureza elétrica, considerando limites de fluxos de linhas, níveis de tensão e estabilidade do sistema. A abordagem do problema em sistemas com diferentes características físicas também ajudam a validar o modelo e calibrar de forma mais precisa os métodos propostos.

Propõem-se também a utilização de outras técnicas metaheurísticas para este tipo de problema e comparação com os métodos aqui apresentados. O aperfeiçoamento dos métodos aqui apresentados é também uma possibilidade, a fim de atingir tempos de simulação reduzidos ou através de um menor número de avaliações da função objetivo ou redução do tempo de simulação necessário para cada avaliação. Sugere-se também estudar os métodos aqui apresentados através da paralelização das simulações, estudando a redução do tempo computacional e sugerindo-se modificações na modelagem.

Outra abordagem sugerida é a utilização da solução em sistemas de característica hidrotérmica, adicionando-se também a modelagem e representação de usinas geradoras termelétricas. A abordagem sobre o ponto de vista da potência, ao invés da vazão, que é abordada neste trabalho, pode também ser estudada, considerando uma modelagem alternativa para a potência de saída das máquinas. Simplificações nos modelos descritos podem também ser abordadas, de forma a se avaliar o impacto de tais alterações na precisão e no tipo de solução obtida para o problema.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] LIMA, A. L. D. S., 2007, *Uma Estratégia de Decomposição por Relaxação Lagrangeana para a Otimização da Programação Diária da Operação de Sistemas Hidrotérmicos com Modelagem Detalhada da Rede Elétrica - Aplicação ao Sistema Brasileiro*, Tese de D.Sc. , COPPE/UFRJ, Rio de Janeiro, Brasil.
- [2] SCUZZIATO, M. R., 2011, *Proposta de um Modelo para Alocação de Unidades Hidrelétricas em Cascata*, Dissertação de M. Sc., Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil.
- [3] MAHOR, A., PRASAD, V., RAGNEKAR S., "Schedulling of Cascaded Hydro Power System: A New Self Adaptive Inertia Weight Particle Swarm Optimization Approach". In: *International Conference on Advances in Recenty Technologies in Communication and Computing*, pp. 565-570, 2009.
- [4] MORENO, S. R., 2012, *Otimização do Planejamento Diário de Geração em Usinas Hidrelétricas*, Dissertação de M. Sc., Universidade Federal do Paraná, Curitiba, PR, Brasil
- [5] LI , A., WANG, L., JI, C., "Application of immune algorithm-based particle swarm optimization for optimized load distribution among csacade hydropower stations," *Computer and Mathematics with Applications* 57, pp. 1785-1791, 2009.
- [6] BARISAL, A. K., CHAKRABARTI, R., HOTA, P. K., "An improved PSO technique for short-term optimal hydrothermal schedulling," *Electric Power Systems Research* 79, pp. 1047-1053, 2009
- [7] GOMES, C. A. M.; FALCÃO, D. M.; PERIN M. L.; LOUÇÃO JUNIOR F. L.; SIMIONI T.; SANTORO, L. P. M.; "Comparison of Metaheuristics Applied to Cascade Hydro Power Plants", VII Simpósio Brasileiro de Sistemas Elétricos – SBSE, Niterói, 2018.

- [8] BASTOS, G. S., 2004, *Otimização da Operação de Centrais Hidrelétricas Pela Distribuição Inteligente de Carga entre Máquinas*, Dissertação de M.Sc., Universidade Federal de Itajubá, Itajubá, Minas Gerais, Brasil
- [9] ONS, Sobre o SIN - O Sistema em números. Disponível em: <http://ons.org.br/pt/paginas/sobre-o-sin/o-sistema-em-numeros>. Acesso em: 03mar 2018, 13:30:00
- [10] RODRIGUES, R. N., 2009, *Um Modelo para a Programação da Operação de Sistemas Hidrotérmicos Baseado em Relaxação Lagrangeana*, Tese de D.Sc., Universidade Federal de Santa Catarina, Florianópolis, Brasil.
- [11] AZEVEDO FILHO, J. M., 2000, *Imperativos da Descentralização e Coordenação da operação Energética no Âmbito da Reforma Institucional do Setor Elétrico Brasileiro*, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil.
- [12] MACEIRA, M. E. P., TERRY, L. A., COSTA, F. S., DAMÁZIO, J. M., MELO, A. C. G., "Chain of Optimization Models for Setting the Energy Dispatch and Spot Price in the Brazilian System", *Proceedings of the Power System Computational Conference – PSCC'02*, Sevilla, Spain, June 2001.
- [13] FINARDI, E. C., 2003, *Alocação de Unidades Geradoras Hidrelétricas em Sistemas Hidrotérmicos Utilizando Relaxação Lagrangeana e Programação Quadrática Sequencial*, Tese de D.Sc., Universidade Federal de Santa Catarina, Florianópolis, Santa Catarina, Brasil.
- [14] ENCINA, A. S. A., 2006, *Despacho Ótimo de Unidades Geradoras Em Sistemas Hidrelétricos Via Heurística Baseada em Relaxação Lagrangeana e Programação Dinâmica*, Tese de D.Sc., Universidade Estadual de Campinas, Campinas, São Paulo, Brasil.
- [15] KENNEDY, J., EBERHART, R., "Particle Swarm Optimization" , *Proc of IEEE International Conference on Neural Networks (ICNN)*, pp. 1942-1948, 1995.
- [16] EBERHART, R., SHI, Y., "A modified Particle Swarm Optimizer", *Evolutionary Computation Proceedings, IEEE World Congress on Computational Intelligence*, pp. 69-73, 1998

- [17] CLERC, M., KENNEDY, J., "The Particle Swarm - Explosion, Stability, and Convergence in a Multidimensional Complex Space", *IEEE Transactions on Evolutionary Computation*, pp. 58-73, Fevereiro 2002.
- [18] KENNEDY, J., EBERHART, R. C., SHI, Y., 2001, *Swarm Intelligence (The Morgan Kaufmann Series in Evolutionary Computation)*, Morgan Kaufmann, Burlington.
- [19] KENNEDY, J., "Small worlds and Mega-Minds: Effects of Neighborhood Topology on Particle Swarm Performance", *Proceedings of the 1999 Congress on Evolutionary Computation*, pp. 1931-1938, 1999.
- [20] PARSOPOULOS, K. E., VRAHATIS, M. N., "UPSO: A Unified Particle Swarm Optimization Scheme," *Lecture Series on Computer and Computational Sciences, Volume 1*, pp. 868-873, 2004.
- [21] HOLLAND, J. H., 1992, *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Application to Biology, Control and Artificial Intelligence*, MIT Press Cambridge, Massachusetts.
- [22] LINDEN, R., 2012, *Algoritmos Genéticos*, 3ed, Rio de Janeiro Ciência Moderna.
- [23] PRICE, K., STORN, R., "Differential Evolution - A simple and efficient adaptive scheme for global optimization over continuous spaces", *Journal of global optimization* 11(4), pp. 341–359 (1997)
- [24] ZHANG, Y., WANG, L., YUAN, Y., YUAN X., "An enhanced differential evolution algorithm for daily optimal hydro generation scheduling" *Computer and Mathematics with Applications* 55 , pp. 2458-2468, 2008.
- [25] TUFEGDZIC, N., FROWD, R. J., STADLIN, W. O., "A Coordinated Approach for Real-Time Short Term Hydro Scheduling" *IEEE Transactions on Power Systems, Vol 11, N° 4*, Novembro 1996.
- [26] CATALÃO, J. P. S., POUSINHO, H. M. I., MENDES, V. M., "Scheduling of head-dependent cascaded reservoirs considering discharge ramping constraints

and start/stop of units.", *Electrical Power and Energy Systems* 32, pp. 904-910, 2010.

- [27] MADERA, R. D. Q., 2013, *Modelagem da função de Produção de uma Usina Hidrelétrica com Base nas Características Individuais das Unidades Geradoras*, Dissertação de M.Sc., Universidade Federal de Santa Catarina, Florianópolis, Brasil,
- [28] SOARES, S., CARNEIRO, A., CIGONA, M., SILVA, D. F., CHAVES, J., “Otimização da Operação Energética das Usinas do rio Paranapanema”, In: *I Congresso de Inovação Tecnológica em energia Elétrica – Citenel*, Brasília, DF, 2001.
- [29] FERREIRA, V. H. SILVA, G. H. C., “Natural optimization Applied to Medium-Term Hydrothermal Coordination” , *Intelligent System Application to Power Systems (ISAP), 2011 16th International Conference*, Hersonissos, Grécia 2011.
- [30] FALCÃO D. M., BORGES, C. L. T., ROCHA, L. F., MACHADO, R. H. S. , DIAS, J. A. S., MOITAS, D. S., “Despacho Conjunto de Máquinas com Previsão de Vazão”, *VI Congresso de Inovação Tecnológica em Energia Elétrica (CITENEL)*, Fortaleza, CE, 2011.