



COPPE/UFRJ

**CONTROLE DE PARÂMETROS EM META-HEURÍSTICAS PARA
COORDENAÇÃO HIDROTÉRMICA NO HORIZONTE DE MÉDIO PRAZO**

Karla Crispina Augusta Roberto

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: Alexandre Pinto Alves da Silva

Rio de Janeiro

Março 2009

CONTROLE DE PARÂMETROS EM META-HEURÍSTICAS PARA
COORDENAÇÃO HIDROTÉRMICA NO HORIZONTE DE MÉDIO PRAZO

Karla Crispina Augusta Roberto

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.

Aprovada por:

Prof. Alexandre Pinto Alves da Silva, Ph. D.

Prof. Luiz Pereira Calôba, Dr. Ing.

Prof. Julio Cesar Stacchini de Souza, D. Sc.

RIO DE JANEIRO, RJ – BRASIL
MARÇO DE 2009

Roberto, Karla Crispina Augusta

Controle de parâmetros em meta-heurísticas para
coordenação hidrotérmica no horizonte de médio prazo /
Karla Crispina Augusta Roberto - Rio de Janeiro:
UFRJ/COPPE, 2009

XI, 119 p.: il.; 29,7 cm.

Orientador: Alexandre Pinto Alves da Silva

Dissertação (Mestrado) – UFRJ/ COPPE/ Programa de
Engenharia Elétrica, 2009.

Referências Bibliográficas: p. 108 - 113.

1. controle de parâmetros. 2. estratégias evolutivas. 3.
coordenação hidrotérmica. 4. meta-heurísticas. I. Silva,
Alexandre Pinto Alves da. II. Universidade Federal do Rio
de Janeiro, COPPE, Programa de Engenharia Elétrica. III.
Titulo.

AGRADECIMENTOS

A Deus, por tudo que Ele tem realizado na minha vida.

À minha família, primeiro aos meus pais Manoel e Aracy, por todo amor, carinho, compreensão e sacrifícios realizados durante todos esses anos para que meus estudos pudessem ser concluídos, à minha irmã Tatiana e ao meu marido Leonardo pela sua paciência infindável, amor e carinho.

A todos os professores que contribuíram para meu amadurecimento profissional e pessoal, em especial ao meu orientador professor Alexandre Pinto Alves da Silva.

A todos que conviveram comigo nos três anos que estive nas dependências do LASPOT, em especial a Aline, Débora, Tatiana, Suzana, Jorge e Hélio.

Um agradecimento especial para o Alexandre Ferreira Amêndola por todo auxílio dado durante a confecção da dissertação, bem como ao Hime Aguiar e Oliveira Jr no auxílio com a meta-heurística recozimento simulado adaptativo difuso.

Muito obrigada a todos!

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

CONTROLE DE PARÂMETROS EM META-HEURÍSTICAS PARA COORDENAÇÃO HIDROTÉRMICA NO HORIZONTE DE MÉDIO PRAZO

Karla Crispina Augusta Roberto

Março / 2009

Orientador: Alexandre Pinto Alves da Silva

Programa: Engenharia Elétrica

Esse trabalho tem como objetivo a solução do problema de coordenação hidrotérmica no horizonte de médio prazo. Para tal, faz-se uso das meta-heurísticas estratégias evolutivas e recozimento simulado adaptativo difuso, motivado pelas suas capacidades de exploração do espaço de busca e possibilidade de adaptação dos parâmetros de controle. Portanto, tais meta-heurísticas são analisadas com o intuito de verificar se são ferramentas eficientes para a solução do problema de interesse no porte do sistema-teste examinado. O sistema-teste é composto de sete usinas hidrelétricas e seis térmicas, sendo simulado com vazões afluentes determinísticas e com vazões afluentes multi-cenários. Os testes realizados com estratégias evolutivas têm oito configurações investigadas visando à auto-adaptação de alguns parâmetros de controle de busca. O recozimento simulado adaptativo difuso é testado em duas versões que correspondem ao tipo de vazão afluente utilizada. Os resultados obtidos são analisados, comparados e expostos graficamente. Conclui-se que o recozimento simulado adaptativo difuso mostrou-se mais adequado em comparação às demais alternativas investigadas. Contudo, as estratégias evolutivas, apesar da necessidade de mais estudos, têm como vantagem a facilidade de implementação.

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

CONTROL OF PARAMETERS IN META-HEURISTICS FOR HYDROTHERMAL
COORDINATION IN THE HORIZON OF MEDIUM PERIOD

Karla Crispina Augusta Roberto

March / 2009

Advisor: Alexandre Pinto Alves da Silva

Department: Electrical Engineering

This work aims at solving the problem of hydrothermal coordination for the horizon of medium term. With that in mind evolutionary strategies and fuzzy adaptative simulated annealing meta-heuristics have been selected, motivated by their capacities of exploring the search space and adapting their control parameters. Therefore, such meta-heuristics are analyzed with the intention of verifying if they are efficient tools for the solution of the problem of interest considering the size of the examined test system. The test system is composed of seven hydroelectric power stations and six thermal units. Simulations have taken into account, deterministic river flows and multi-scenarios flow. The tests with evolutionary strategies have investigated eight configurations seeking to the auto-adaptation of some parameters of search control. The fuzzy adaptative simulated annealing has been tested in two versions, depending on the river flows been assumed deterministic or not. The obtained results are analyzed, compared and exposed graphically. It has been concluded that fuzzy adaptative simulated annealing seems to be more appropriate in comparison with the other investigated alternatives. However, the evolutionary strategies, in spite of requiring more investigation, have the advantage of being easier to implement.

ÍNDICE

CAPÍTULO 1	1
INTRODUÇÃO.....	1
1.1 - Motivação.....	1
1.2 - Objetivo.....	2
1.3 - Revisão bibliográfica	2
1.4 - Contribuições do trabalho	8
1.5 - Estrutura	9
CAPÍTULO 2	11
PROGRAMAÇÃO DA GERAÇÃO	11
2.1 - Introdução.....	11
2.2 - Programação da geração térmica	14
2.3 - Programação da geração hidrotérmica	16
CAPÍTULO 3	24
META-HEURÍSTICAS	24
3.1 - Introdução.....	24
3.2 - História.....	25
3.3 - Controle de Parâmetros.....	27
3.3.1 – Parâmetros Fixos	28
Algoritmo Genético.....	29
3.3.2 – Controle de Parâmetro Determinístico	34
Recozimento Simulado.....	34
3.3.3 - Controle de Parâmetro Adaptativo.....	36
Enxame de Partículas	36
Recozimento Simulado Adaptativo Difuso	40
Recozimento Simulado Adaptativo.....	40
Lógica Difusa.....	42
3.3.4 - Controle auto-adaptativo de parâmetros.....	46
Estratégias Evolutivas	47
Algoritmo Genético.....	53

CAPÍTULO 4	55
SISTEMA-TESTE E RESULTADOS.....	55
4.1 - Introdução.....	55
4.2 - Sistema Teste.....	55
4.3 - Aplicação das estratégias evolutivas no sistema teste	68
4.4 - Aplicação do recozimento simulado adaptativo difuso no sistema teste	77
4.5 - Resultados	78
4.5.1 - Testes com estratégias evolutivas	78
4.5.2 - Testes com recozimento simulado adaptativo difuso.....	89
4.6 - Análise gráfica.....	92
4.7 - Análise dos resultados.....	99
CAPÍTULO 5	104
CONCLUSÕES	104
REFERÊNCIAS BIBLIOGRÁFICAS.....	108
ANEXO.....	114
FUNÇÃO ADEQUABILIDADE	114

Índice de Figuras

Figura 2.1 - Constituição de um Sistema de Energia Elétrica.....	11
Figura 2.2 - Funções Custo Total, Imediato e Futuro.....	13
Figura 2.3 - Curva Típica da Geração Térmica.....	16
Figura 2.4 - Esquema Básico de uma Usina Hidrelétrica.....	17
Figura 3.1 – Classificação do Ajuste de Parâmetros.....	28
Figura 3.2 - Pseudo Código de Algoritmo Genético.....	29
Figura 3.3 - Cruzamento de um Ponto.....	30
Figura 3.4 - Cruzamento de dois Pontos.....	30
Figura 3.5 - Cruzamento Uniforme.....	31
Figura 3.6 - Esquema Mutação.....	31
Figura 3.9 - Pseudocódigo do Enxame de Partículas.....	38
Figura 3. 10 - Esquema de Geração de Pontos no Recozimento Simulado Adaptativo.	42
Figura 3.11 - Pseudocódigo de Estratégias Evolucionárias.	48
Figura 3.12 - Esquema da Recombinação Discreta.....	49
Figura 3.13 - Esquema da Recombinação Intermediária.....	50
Figura 3.14 - Esquema da Recombinação Intermediária Com Mais de dois Pais.....	50
Figura 3.15 - Esquema da Recombinação de um Ponto.....	50
Figura 4.1 - Usinas em Estudo Na Bacia do Rio São Francisco.	56
Figura 4. 2 - Simulador de Operação da Cascata das Usinas do Sistema-Teste.	66
Figura 4.3 - Esboço do Funcionamento do Algoritmo.....	69
Figura 4.4 - Esboço do Funcionamento do Algoritmo no Caso 1.	71
Figura 4.5 - Esboço do Funcionamento do Algoritmo no Caso 2.	72
Figura 4.6 - Esboço do Funcionamento do Algoritmo no Caso 3.	73
Figura 4.7 - Esboço do Funcionamento do Algoritmo no Caso 4.	74
Figura 4.8 - Esboço do Funcionamento do Algoritmo no Caso 5.	74
Figura 4.9 - Esboço do Funcionamento do Algoritmo no Caso 6.	75
Figura 4.10 - Esboço do Funcionamento do Algoritmo no Caso 7.	76
Figura 4.11 - Esquema de Funcionamento do Recozimento Simulado Adaptativo Difuso. 78	
Figura 4.12 - Geração Segmentada por Fonte.	92

Figura 4.13 - Armazenamento dos Reservatórios em Hm ³	93
Figura 4.14 - Armazenamento Percentual do Volume Útil.....	93
Figura 4.15 - Geração Segmentada por Fonte.....	94
Figura 4.16 - Armazenamento dos Reservatórios em Hm ³	95
Figura 4.17 - Armazenamento Percentual do Volume Útil.....	95
Figura 4.18 - Geração Segmentada por Fonte.....	96
Figura 4.19 - Armazenamento dos Reservatórios em Hm ³	96
Figura 4.20 - Armazenamento Percentual do Volume Útil.....	97
Figura 4.21 - Geração Segmentada por Fonte.....	98
Figura 4.22 - Armazenamento dos Reservatórios em Hm ³	98
Figura 4.23 - Armazenamento Percentual do Volume Útil.....	99

Índice de Tabelas

Tabela 3.1 – Modo de Seleção Proporcional.....	32
Tabela 3.3 - Tabela de Cronograma de Recozimento.....	41
Tabela 4.1 - Características da Usinas Hidrelétricas.	57
Tabela 4.2 - Três Marias.	58
Tabela 4.3 - Sobradinho.	59
Tabela 4.4 - Itaparica.	60
Tabela 4.5 - Moxotó.....	61
Tabela 4.6 - Paulo Afonso 1, 2, 3.	62
Tabela 4.7 - Paulo Afonso 4.....	63
Tabela 4.8 - Xingó.	64
Tabela 4.9 - Características da Usinas Térmicas.....	65
Tabela 4.10 - Despacho Térmico Otimizado.....	65
Tabela 4.11 - Testes Realizados com Torneio 4.....	79
Tabela 4.12 - Testes Realizados no Caso 2.....	80
Tabela 4.13 - Testes Realizados no Caso 3.....	82
Tabela 4.14 - Testes Realizados no Caso 4.....	83
Tabela 4.15 - Testes Realizados no Caso 5.....	84
Tabela 4.16 - Testes Realizados com o Caso 6.	86
Tabela 4.17 - Testes Realizados Caso 8.....	88
Tabela 4.18 - Testes Realizados com a MLT de Vazões.	89
Tabela 4.19 - Testes Realizados com Múltiplos Cenários de Vazão.....	90
Tabela 4.20 - Resultados Estratégias Evolutivas.....	99
Tabela 4.21 - Melhores Resultados da Estratégias Evolutivas com Vazões Determinísticas	100
Tabela 4.22 - Menores Resultados Estratégias Evolutivas com Vazões Determinísticas..	101
Tabela 4.23 - Resultados Recozimento Simulado Adaptativo Difuso.....	101
Tabela 4.24 - Comparação para o Cenário Determinístico.	102
Tabela 4.25 - Comparação para o Cenário Estocástico.	102
Tabela 4.26 - Comparação dos Resultados.	103

Capítulo 1

Introdução

1.1 - Motivação

A dependência da eletricidade fica mais evidente a cada dia, não só no Brasil, mas no mundo inteiro, produzindo um aumento crescente da demanda de energia elétrica que deve ser suprida de forma contínua e confiável. Para tal, faz-se necessário que o sistema que fornece essa energia cresça junto com a carga. A expansão de um sistema elétrico envolve muitas dificuldades, como a disponibilidade de recursos financeiros para a construção de novas usinas hidrelétricas e térmicas, bem como as restrições associadas a essas construções, como exemplo, as ambientais. Pelos motivos citados, é de grande importância que haja um maior aproveitamento do parque energético já existente.

O planejamento da operação de sistemas hidrotérmicos tem o objetivo de minimizar os custos, usando ao máximo as usinas hidrelétricas e ao mínimo as térmicas, através da otimização dos recursos existentes. No entanto, essa tarefa se mostra complexa devido à quantidade de decisões que devem ser tomadas e ao grande número de restrições e incertezas envolvidas nesse problema, como: modo do uso da água existente nos reservatórios, restrições operativas do sistema de transmissão, acoplamento entre as usinas hidrelétricas, incertezas das afluências, entre outras.

A grande quantidade de incertezas e restrições dificulta o uso de algumas técnicas clássicas de otimização que necessitam de funções que tenham um comportamento “suave” como, por exemplo: linearidade, convexidade ou continuidade. Entretanto, há técnicas capazes de lidar com funções objetivos não lineares, não convexas, ou mesmo não diferenciáveis, como os algoritmos que utilizam a evolução como princípio. Entre eles estão: algoritmo genético, enxame de partículas, colônia de formigas e estratégias evolutivas. Essas técnicas foram, durante décadas, pouco aplicadas, até ressurgirem com força na década de 90. O crescente desenvolvimento da tecnologia computacional auxilia

na aplicação dessas técnicas evolutivas, que podem se tornar ferramentas poderosas na resolução de problemas complexos como a coordenação hidrotérmica.

1.2 - Objetivo

O foco dessa dissertação é a solução do problema de coordenação hidrotérmica, em médio prazo, utilizando as meta-heurísticas estratégia evolutiva e recozimento simulado adaptativo difuso. Essas técnicas foram escolhidas por possuírem como características: ampla exploração do espaço de soluções e a auto-adaptação dos parâmetros de busca.

Os testes que serão realizados com objetivo de minimizar os custos da coordenação hidrotérmica terão duas análises: a primeira com vazões determinísticas e a segunda com vazões multi-cenários. Os resultados obtidos ao final dos testes das vazões determinísticas serão comparados com os obtidos na dissertação [1], na qual foram empregadas: algoritmo genético, enxame de partículas e recozimento simulado. Em contrapartida, os resultados obtidos nos testes com vazões de múltiplos cenários serão utilizadas como desafio maior para as técnicas de estratégia evolutiva e recozimento simulado adaptativo difuso.

1.3 - Revisão bibliográfica

A seguir, descrevem-se várias contribuições importantes para o estado-da-arte em coordenação hidrotérmica, onde se observa participação intensa de grupos brasileiros. No ano de 1980, S. SOARES, C. LYRA e H. TAVARES, em [2], utilizam técnicas de decomposição com o objetivo de minimizar o custo da operação de sistemas hidrotérmicos. O modelo foi desenvolvido para lidar com sistemas de grande porte de forma geral e precisa, de modo que incluísse: custo da operação térmica, custo da geração hidrelétrica, funções não lineares, demandas de cargas estocásticas, usinas em cascatas, entre outras restrições. As técnicas utilizadas para a resolução consistiam em transformar a carga estocástica (restrição dinâmica) em um modelo equivalente determinístico. Devido ao grande porte do problema, a decomposição dual¹ é aplicada para a obtenção de subsistemas

mais fáceis de resolver. Para solucionar os subsistemas são aplicadas técnicas baseadas na teoria de Lagrange. Os multiplicadores de Lagrange que surgem nos subproblemas possuem interpretações econômicas que facilitavam assim a escolha de seus valores iniciais. Os autores concluem que o modelo testado atinge o objetivo proposto. O tempo de execução não é elevado comparado a estudos mais simples e segundo os autores pode ser reduzido com melhorias na programação e nos valores iniciais dos multiplicadores de Lagrange.

No ano 1982, M. V. F. PEREIRA, L. M. V. G. PINTO [3], apresentam um artigo no qual há uma abordagem do uso de decomposição para solucionar o problema do pré-despacho, modelando-o como um programa linear de larga escala e resolvido por decomposição de Dantzig-Wolfe². Os subproblemas que surgem, correspondem a problemas de reprogramação ótima horária e são solucionados com uma versão do método simplex dual³. O sistema usado para testar foi a rede sudeste do Brasil.

Em 1984, C. LYRA, H. TAVARES e S. SOARES, em [4], propõem um modelo para operar em médio prazo, no qual consideram um período entre semanas e um ano, onde as afluências são consideradas como conhecidas (determinísticas). A aleatoriedade da carga é considerada e um modelo detalhado é utilizado para representar os sistemas hidráulicos e os sistemas não hídricos. Com o objetivo de superar as dificuldades de um sistema de grande porte utilizaram-se técnicas de decomposição dual.

¹ A decomposição dual é aplicada para transformar o problema de grande porte em subsistemas menores através da relaxação Lagrangeana.

² O método de decomposição de Dantzig-Wolfe é aplicado em problemas de programação linear de grandes dimensões porque aproveita a estrutura da matriz que rege o problema para reduzir a dimensão da base, formando assim um problema equivalente com uma grande redução do número de restrições.

³ O método simplex dual é utilizado para resolver problemas de programação linear e demanda um menor esforço computacional em comparação ao método primal em problemas de um número elevado de variáveis envolvidas.

Em 1985, [5], de J. J. SHAW, R. F. GENDRON e D. P. BERTSEKAS apresenta um novo algoritmo que procura soluções ótimas para sistemas hidrotérmicos de grande porte, o que significa enfrentar um problema de não linearidades e de grande número de variáveis. Eles fazem uso da programação dinâmica dual para programar uma semana de 100 unidades térmicas e 6 usinas hidrelétricas. O modelo é computacionalmente eficiente, com o tempo de processamento variando linearmente com o número de térmicas e sendo próximo à ordem quadrática para o número de hidrelétricas.

No ano de 1986, [6], de V. BISSONNETE, L. LAFOND e G. CÔTÉ mostra os esforços para projetar e implementar um modelo de programação hidrotérmica em médio prazo da Hydro-Québec, que possui 52 hidrelétricas, uma usina nuclear e 27 termelétricas, cujos combustíveis são óleo ou gás. O horizonte de estudo é um período entre um e dois anos com discretização semanal e os dados de entrada são assumidos como conhecidos. O modelo é detalhado com descrição da natureza não-linear das usinas hidrelétricas. Para suprir a diferença entre a carga contratada e a geração hidrelétrica as térmicas são utilizadas. A técnica de solução é de programação não linear adaptada ao problema.

Em 1987, M. F. CARVALHO e S. SOARES, em [7], apresentaram um algoritmo para a programação de sistemas hidrotérmicos com vazões determinísticas. A representação do sistema é feita através de fluxo em redes não-linear. A estrutura da rede é dada através de ramificações especiais chamadas arborescência expandida no tempo. Essas ramificações são compostas de nós, que representam cada usina, e cada nó possui duas saídas. Nesse caso, uma saída representa o volume do reservatório e a outra a vazão defluente, o que beneficia a redução do tempo de execução, pois possibilita o uso de duas técnicas: a estrutura de base direcionada e a escolha de base dinâmica. A estrutura de base direcionada consiste em separar as variáveis do problema em básicas e não básicas. Como no método do gradiente reduzido, onde essa separação faz com que somente variável não básica seja utilizada para a determinação da direção da descida, essa separação faz com que o algoritmo de fluxo em rede se desenvolva usando somente um tipo de variável. As variáveis básicas são as dependentes enquanto as não básicas são as variáveis

independentes. A escolha da base varia de acordo com cada sistema hidrelétrico podendo ser: a vazão defluente e o volume do reservatório, somente a vazão defluente, ou somente o volume do reservatório, que é o mais utilizado. Essa base pode ser escolhida e modificada durante o processo iterativo e por isso é denominada: escolha de base dinâmica. Esse algoritmo é testado no sistema do sudeste brasileiro composto de vinte usinas hidrelétricas acopladas em cascata e os resultados se mostraram satisfatórios, demandando um tempo de execução de 2,2 segundos em um computador PDP-10.

No ano de 1990, [8], de A. A. F. M. CARNEIRO, S. SOARES e P. S. BOND, apresenta um algoritmo de otimização determinística, baseado no fluxo em redes especialmente desenvolvido para o caso hidrotérmico. O algoritmo foi aplicado no sistema interligado Sul-Sudeste do Brasil composto de 50 hidrelétricas, 12 térmicas e 45GW de capacidade instalada. Os dados utilizados eram da base operacional da Eletrobrás em 1986. Duas aplicações foram testadas: a primeira um estudo do sistema na situação mais crítica sob o ponto de vista das aflúncias, e a segunda onde o sistema é simulado através do planejamento operacional adaptado. Esse planejamento é uma solução sub-ótima para problemas na versão estocástica na qual a solução ótima não é possível de ser encontrada, devido ao dimensionamento, via programação dinâmica estocástica. Ele consiste na otimização do problema para cada período de tempo, no caso mensal, para as aflúncias previstas, com objetivo de obter a decisão de vazão para o período de análise. Os resultados mostram que o algoritmo poderia ser uma ferramenta para o planejamento de grandes sistemas hidrotérmicos.

No mesmo ano, A. J. CONEJO, M. C. CARAMANIS e J. A. BLOOM [9] apresentam um algoritmo que determina a utilização ótima de reservatórios de armazenamento bombeado explorando a natureza linear por partes da função que diz respeito ao nível de utilização dos reservatórios. Esse algoritmo possui o diferencial de não fazer o cálculo do custo do sistema em cada iteração como é feito normalmente. Nesse algoritmo são feitas pequenas alterações no bombeamento e turbinamento, afetando assim a energia gerada em poucas usinas térmicas. Como consequência, há uma redução

significativa no tempo computacional. O ganho na eficiência computacional independe da representação da curva de carga utilizada pelo modelo de custo de produção.

Em 1991, S. SOARES e A. A. F. M. CARNEIRO, [10], discorrem sobre a operação ótima de reservatórios apresentando relatórios de testes realizados em sistemas simples sob condições especiais. Os testes foram realizados de modo progressivo para que a influência de diversos fatores, como nível do reservatório, taxas de descontos, sazonalidades das afluições e configuração do sistema, ficassem evidentes. As conclusões indicam um modo adequado de se planejar a operação de sistemas hidrotérmicos no longo prazo. O sistema proposto lida com características como: não-linearidade do custo térmico e das funções da geração hidrelétrica, operação interdependente entre as hidrelétricas em cascata, natureza da carga e das afluições.

Em 1993, [11], de C. LI, P. J. JAP e D. L. STREIFFERT, apresentam um artigo dividido em duas partes principais. A primeira descreve o algoritmo de fluxo em redes incremental e a segunda versa sobre a implementação do programa no sistema de gerenciamento de energia e sua interface com o software de despacho térmico.

No ano de 1997, LI e outros, em [12], relatam um novo modelo para lidar com a programação hidrotérmica e com as restrições associadas às usinas hidrelétricas visando à operação econômica do sistema. Nesse modelo a parte relacionada às usinas térmicas é solucionada por relaxação Lagrangeana enquanto a parte hidrelétrica é dividida em bacias e subdividida em reservatórios. As bacias são otimizadas através de fluxo em redes e os reservatórios pela técnica de programação dinâmica.

Em 1999, M. A. CIGOGNA desenvolveu em sua dissertação de mestrado, [13], um modelo de otimização a usinas individualizadas para o planejamento da operação no horizonte de médio e longo prazo, sendo o modelo de otimização baseado em um algoritmo de fluxo em redes não linear com arco capacitado. No mesmo ano, A. S. A. ENCINA em sua dissertação de mestrado, [14], analisou a otimização do despacho de máquinas considerando as partidas e paradas das máquinas e as perdas devido, por exemplo, a

elevação do nível de fuga, a variação do rendimento do conjunto turbina gerador, e ao aumento do atrito do fluxo d'água nas tubulações do sistema hidráulico.

Em 2003, [15] de M. E. P. MACEIRA, V. S. DUARTE, R. M. MARCATO, A. L. M. MARCATO e V. M. da COSTA, tinha o objetivo de quantificar a influência do tipo de vazão afluyente considerada no planejamento, se estocástica ou determinística. O artigo considera como determinísticas as previsões de vazões e como estocástico um conjunto de cenários hidrológicos que representem as aleatoriedades e as incertezas. Para a programação estocástica utilizam a programação dinâmica dual estocástica, enquanto na determinística é aplicada a programação dual determinística. O estudo é dividido em duas etapas, uma é a determinação da política ótima de operação, quando é definido o tipo de abordagem das afluências, e a outra é a fase da simulação da operação. Os autores concluem que se fosse possível que as previsões de vazões se confirmassem, a programação via vazões determinísticas seria a melhor a ser adotada. No entanto, como é impossível se ter certeza das afluências, à programação que utiliza a estocasticidade se mostra melhor por fornecer melhores índices como: menor risco de déficit e do custo de operação. No mesmo ano, [16], na dissertação de mestrado de F. PROVEÇANO analisa-se o despacho ótimo e pré-despacho sob duas visões: a primeira modelando esses problemas com objetivo de minimizar a água consumida a montante e a segunda minimizando as perdas. As perdas estão associadas ao conjunto turbina-gerador, sendo elas: as perdas hidráulicas, perdas pela elevação do canal de fuga e pela variação de perda nas turbinas.

No ano de 2005, C.J. P. HUMPIRI em sua dissertação de mestrado [17] faz uso de estratégias evolutivas para o planejamento da operação e compara essa meta-heurística com programação não linear baseada em fluxos em redes. A autora realizou uma série de oito simulações, onde a maioria tinha como afluência base a vazão média de longo termo, a MLT, considerando o período entre maio de 1931 e abril de 1998. A demanda de carga tinha valor constante e a potência instalada das usinas testadas eram as consideradas nos testes. Em cada teste foram comparadas a programação não-linear e as estratégias evolutivas. Os resultados foram favoráveis às estratégias evolutivas, pois em nenhum teste essa técnica apresentou resultados piores do que a programação não linear.

Em 2006, CASTRO, CARNEIRO e ANDRADE publicaram [18], que mostra o desenvolvimento e a aplicação de um algoritmo que combina os modelos estocástico e determinístico com o objetivo de individualizar a representação das usinas hidrelétricas no planejamento em médio prazo.

Em 2007, [1], na dissertação de mestrado de A. F. AMENDOLA utilizou-se algoritmo genético, enxame de partículas e recozimento simulado como métodos de solução para a coordenação hidrotérmica a usinas individualizadas com vazões afluentes determinísticas. O autor conclui que o recozimento simulado foi a meta-heurística que apresentou a melhor qualidade média na solução, além de fornecer a melhor solução global e a menor variância nos resultados. Na busca de uma comparação, o sistema utilizado foi testado pelo pacote de otimização da Frontline Solver Plataform, que utiliza o método de otimização não linear GRG (Generalized Reduced Gradient). O resultado encontrado nessa plataforma foi cerca de 10% inferior ao melhor resultado encontrado quando utilizada as meta-heurísticas citadas anteriormente. No entanto, vale ressaltar que houve a necessidade de ajustes e a adoção de procedimentos interativos “manuais” que exigiam um conhecimento prévio do problema, o que deixa em vantagem as meta-heurísticas que dispensam tais procedimentos.

As duas últimas dissertações citadas [17,1] foram de grande importância para o desenvolvimento desse trabalho. A primeira por apontar que é possível bom resultado para a programação da geração e a segunda por ser a base comparativa de resultados.

1.4 - Contribuições do trabalho

A proposta da presente dissertação é aplicar as meta-heurísticas estratégia evolutiva e recozimento simulado adaptativo difuso [19] para a solução do problema de programação da geração. O uso da estratégia evolutiva contribui como um acréscimo ao trabalho iniciado em [1], onde diversas técnicas que utilizam a evolução como princípio foram implementadas.

Outra contribuição existente é o fato do algoritmo ter sido submetido à vazão afluente de múltiplos cenários, onde o desafio foi encontrar uma solução ótima que atendesse desde o cenário mais seco até o mais úmido registrado na bacia onde está localizado o sistema-teste.

O sistema-teste também foi submetido a outro algoritmo, o recozimento simulado adaptativo difuso, tanto para o cenário de vazão afluente de média a longo termo, como nos múltiplos cenários. A implementação dessa outra técnica que é utilizada, por exemplo, em projeto de filtros digitais, treinamento de redes neurais, entre outras aplicações, também pode ser considerada uma contribuição desse trabalho.

1.5 - Estrutura

A dissertação está dividida em cinco capítulos: Introdução, Programação da Geração, Meta-heurísticas, Sistema Teste e Resultados e Conclusões.

O capítulo 1 introduziu o tema da dissertação, descrevendo a motivação, citando algumas referências bibliográficas sobre o planejamento energético da operação, bem como expõe os objetivos e as contribuições desse trabalho.

O capítulo 2 descreve o problema da programação da geração, que no caso hidrotérmico consiste em otimizar o uso das hidrelétricas e das térmicas do sistema. Para tal divide-se o capítulo em programação da geração térmica e programação da geração hidrotérmica. Na seção sobre programação da geração térmica, descrevem-se os tipos de usinas existentes e apresenta-se a modelagem dessa programação. Na seção de programação hidrelétrica, descreve-se como é a modelagem do problema, suas restrições e variáveis envolvidas.

No capítulo 3, há um pequeno histórico de como algumas técnicas que usam evolução como princípio surgiram. Nesse capítulo também serão descritos os vários modos

de se realizar o controle dos parâmetros existentes e a partir disso, haverá uma descrição das meta-heurísticas que foram implementadas nessa dissertação, estratégias evolutivas e recozimento simulado adaptativo difuso; e em [1] algoritmo genético, recozimento simulado e enxame de partículas.

O capítulo 4 apresenta o sistema teste, o modo como a estratégia evolutiva é utilizada, bem como o recozimento simulado adaptativo difuso e os resultados obtidos através de tabelas e gráficos, além de uma comparação com os resultados obtidos na dissertação [1]. No capítulo 5, encontram-se as conclusões do trabalho e sugestões para trabalhos futuros.

Capítulo 2

Programação da Geração

2.1 - Introdução

Um sistema de energia elétrica é constituído basicamente por geração, transmissão, distribuição e carga. A geração de energia pode vir de fontes renováveis, exemplo água, ou não-renováveis, como os combustíveis fósseis, dependendo do tipo de usina.

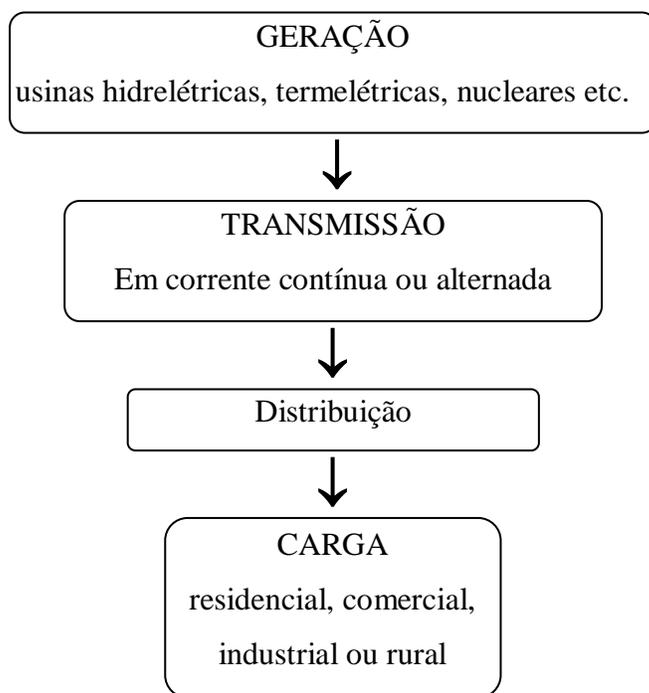


Figura 2.1 - Constituição de um sistema de energia elétrica

No Brasil, o sistema de energia elétrica é dividido entre pequenos sistemas isolados e o sistema interligado nacional, o SIN. Os pequenos sistemas isolados são compostos de pequenas centrais geradoras, geralmente termelétricas a óleo diesel, localizadas principalmente na região Norte. Em contrapartida, o SIN é um sistema de grande porte hidrotérmico, com predominância hidrelétrica, formado por empresas localizadas no Sul, Sudeste, Centro-Oeste, Nordeste e parte do Norte, contendo assim 96,6% da capacidade de produção de energia elétrica do País [20].

O SIN tem suas instalações de geração e transmissão controladas e coordenadas pelo Operador Nacional do Sistema Elétrico, o ONS, desde 1998. O ONS por sua vez é fiscalizado e regulamentado pela Agência Nacional de Energia Elétrica, a ANEEL, criada em 1996.

O Brasil tem como sua principal fonte de energia a energia hidráulica, sendo assim, o nível de armazenamento da água nos reservatórios é um limitador da geração de cada usina. O modo no qual utilizamos a água existente em cada um deles pode influenciar no valor da energia gerada e no não atendimento da demanda no futuro.

Existem duas possibilidades de decisão quanto ao nível dos reservatórios: o uso do reservatório ou a manutenção do nível do mesmo, e cada decisão possui uma consequência no futuro, como visto na tabela 2.1.

Tabela 2.1 - Análise da operação em função do reservatório e das afluições futuras.

Afluência futura	Alta	Baixa
Reservatório		
Uso	Operação econômica	Déficit de energia
Manutenção do nível	Vertimento	Operação econômica

As funções custo futuro e imediato (Figura 2.2) representam os custos das decisões descritas na tabela 2.1. Quando os recursos hídricos são usados totalmente para atender a demanda, o volume máximo do reservatório atinge zero e o custo imediato é zero, no entanto, o valor do custo futuro é elevado. Quando os reservatórios são totalmente preservados, ou seja, o volume é de 100%, o custo futuro é zerado, entretanto, o valor do custo imediato é alto. Como mostrado, na figura 2.2, a decisão ótima é uma combinação entre o uso dos recursos térmicos e hidráulicos.

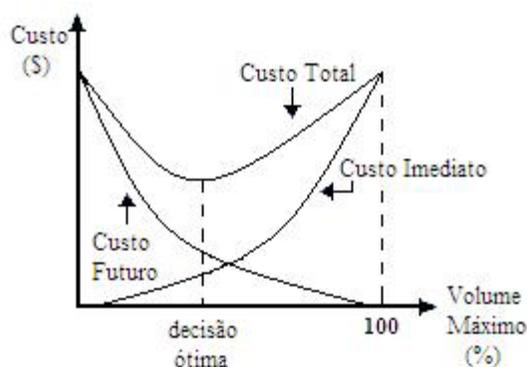


Figura 2.2 - Funções custo total, imediato e futuro

Os despachos de sistemas hidrotérmicos têm como objetivo minimizar o custo da operação do sistema, consistindo em despachá-lo de maneira ótima levando em consideração as restrições operativas associadas às usinas térmicas e hidrelétricas, e os recursos hídricos disponíveis no presente e no futuro, a fim de fazer um planejamento a curto, médio e longo prazo, visando garantir o atendimento da demanda. Quando não há essa possibilidade, o objetivo do pré-despacho é minimizar o déficit de carga.

Tabela 2.2 - Horizontes de planejamento da operação.

Planejamento	Horizonte de estudo	Discretização
Longo prazo	Acima de 5 anos	anual
Médio prazo	Até 5 anos	mensal
Curto prazo	Até 1 ano	mensal

O despacho hidrotérmico é subdividido, geralmente, em três etapas: coordenação hidrotérmica, pré-despacho térmico e o despacho econômico. A coordenação hidrotérmica determina a quantidade ótima de geração, tanto térmica quanto hidrelétrica, para um dado período de tempo.

O pré-despacho térmico consiste em determinar quais unidades térmicas gerarão a quantidade de energia estabelecida pela coordenação hidrotérmica para a geração térmica, ou seja, quais são as unidades que estarão funcionando a cada intervalo de tempo, a fim de se atender a carga elétrica. O despacho econômico determina a quantidade de energia gerada por cada usina térmica selecionada pelo despacho térmico em cada intervalo de tempo.

O planejamento da operação do sistema interligado brasileiro é realizado através de uma cadeia de diversos programas desenvolvidos pelo CEPEL, Centro de Pesquisas de Energia Elétrica, com objetivo do planejamento a longo, médio, curto e curtíssimo prazo. O foco da presente dissertação é o planejamento em médio prazo, no qual atualmente é utilizado para o planejamento e a operação o programa DECOMP [21].

O objetivo do programa é determinar a geração de cada usina de modo a atender a demanda e minimizando os custos operativos no período a ser planejado [21]. O modelo DECOMP considera o planejamento de doze meses com discretização mensal. Vale ressaltar que o primeiro mês pode ser discretizado em até seis semanas [22]. O modelo representa as usinas e as restrições operativas individualmente, e utiliza a programação linear em cada intervalo de tempo para solucionar o problema de operação e planejamento do sistema.

2.2 - Programação da geração térmica

Usinas térmicas são usinas que utilizam combustíveis para gerar energia elétrica, elas se dividem em duas grandes categorias: as convencionais e as nucleares. As usinas térmicas convencionais usam combustíveis fósseis como fonte de energia e se subdividem em usinas com combustão direta, turbinas a vapor e a gás.

As usinas de combustão direta funcionam com o combustível alimentando um motor diretamente acoplado a um gerador. Nas turbinas a vapor, há a queima de um combustível que aquece a água na caldeira, gerando vapor, que sob pressão, movimenta a turbina conectada a um gerador. As usinas a gás utilizam uma mistura de ar comprimido com o gás obtido na queima do combustível para que a turbina se movimente e acione o gerador.

As usinas nucleares utilizam os combustíveis físséis como fonte de energia. A representação das usinas térmicas no despacho é baseada nas suas características físicas e restrições operativas, como apresentado a seguir.

Despacho térmico

O planejamento da geração para um sistema térmico é baseado no conhecimento da capacidade de geração de cada usina, bem como dos custos operativos associados a cada uma. Alguns custos são considerados fixos, como os associados à manutenção, por exemplo, e com isso são desconsiderados para efeito de modelagem. O custo variável de operação é o custo de combustível, que pode ser aproximado por uma função de 2º grau, sendo limitado pela geração máxima e mínima da usina, como vemos nas equações 2.1 e 2.2 e na figura 2.3 [17].

$$\Psi_j(g_j) = ag_j^2 + bg_j + c \quad (2.1)$$

Sujeito a

$$g_{j\text{mín}} \leq g_j \leq g_{j\text{máx}}$$

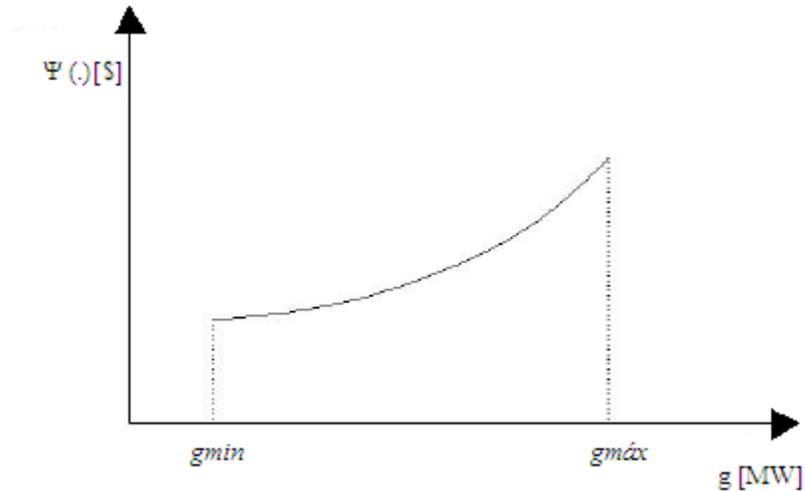


Figura 2.3 - Curva típica da geração térmica

O pré-despacho pode ser feito de modo que as usinas com menores custos incrementais sejam despachadas antes das mais custosas. Em sistemas de grande porte, pode ser empregada a programação linear para a definição do despacho. Algumas características marcantes da programação da geração térmica são: ser desacoplada no tempo, o atendimento da demanda estar relacionado à capacidade de geração do parque térmico e o custo incremental de cada unidade ser independente da geração das outras usinas.

$$\min \sum_{j=1}^J \psi_j(g_j), \quad \forall j \quad (2.2)$$

2.3 - Programação da geração hidrotérmica

Introdução

Uma usina hidrelétrica é composta basicamente de uma barragem, condutos forçados, casa de máquinas e canal de restituição. A barragem tem a função de produzir a diferença de nível no rio e represá-lo, permitindo assim a acumulação da água, que formará o reservatório. O conduto forçado é por onde a água passa até chegar à casa de máquinas,

possibilitando assim a transformação da energia potencial em energia mecânica. O canal de restituição leva a água novamente ao rio. A figura 2.4, ilustra o processo.

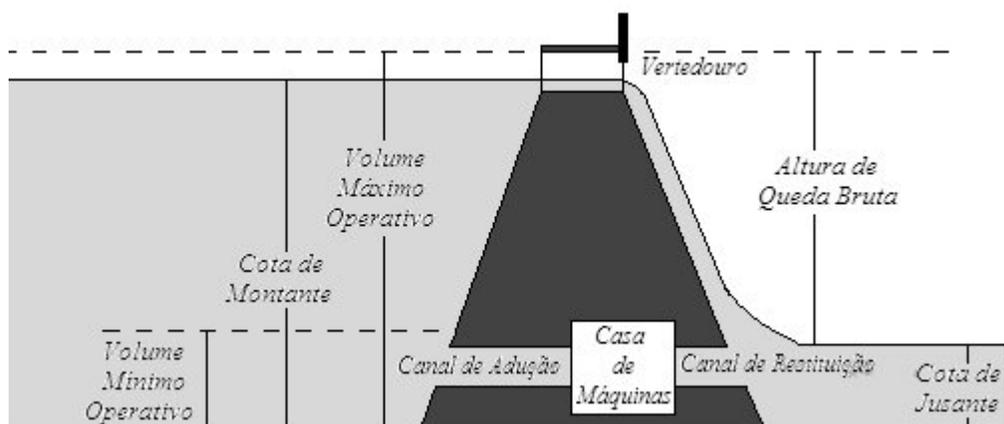


Figura 2.4 - Esquema básico de uma usina hidrelétrica

Despacho hidrotérmico

Os despachos das usinas hidrelétricas dependem do tipo de usina. As usinas a fio d'água são sempre as primeiras usinas a serem despachadas. Por não possuírem reservatórios, ou possuírem pequenos reservatórios, todo volume de água que chega à usina deve gerar energia. As usinas de armazenamento bombeado funcionam por ciclos, bombeando ou gerando, e geralmente são despachadas em horários de pico. Nas usinas de reservatório, por possuírem reservatórios sujeitos a restrições de armazenamento, os despachos são decididos de acordo com interesses econômicos, armazenamento disponível e previsões de afluências. Normalmente são despachadas para gerar o máximo possível em um dado horizonte de tempo, minimizando a utilização de geração térmica.

A programação hidrotérmica possui como características principais: o acoplamento espacial, ou seja, a operação de uma usina exerce influência na usina a jusante; e a estocasticidade introduzida pelos vários cenários de afluências futuras.

Modelagem do problema hidrotérmico

Os sistemas hidrotérmicos possuem a energia gerada limitada pela capacidade de armazenamento dos reservatórios das usinas hidrelétricas. A água que chega ao reservatório é de natureza estocástica e por isso é necessária uma boa modelagem do problema com suas variáveis e restrições, com o objetivo de que a carga sempre seja suprida do modo mais eficiente possível. Para tal é importante o conhecimento de todas as variáveis envolvidas no problema.

Variáveis do problema

O volume do reservatório é geralmente medido em hm^3 , e é representado pela variável x . Segundo a capacidade de regularização pode ser classificado como: reservatórios de compensação ou de acumulação. Nos reservatórios de compensação o volume de água pode regularizar vazões diárias ou semanais, enquanto nos reservatórios de acumulação o volume armazenado pode acumular água suficiente para regularizar vazões por períodos que podem variar de um mês até anos.

Quanto ao uso, é dividido em: volume morto, útil e de segurança [13]. O volume morto representa o volume de água mínimo para a geração de energia, pois, abaixo dele a água não consegue entrar no canal de adução. O volume útil corresponde à água que gera energia, e está delimitado pelas cotas de operação mínimas e máximas. O volume de segurança é o espaço no reservatório o qual não é preenchido por água com o objetivo de manter uma faixa para o controle das cheias, está localizada entre a cota de operação máxima e a cota maximorum do aproveitamento. A cota maximorum é a altura máxima na qual o reservatório pode ser preenchido de água sem que a usina entre em colapso. Caso o volume de água supere essa cota, o canal vertedouro é aberto para que através dele a água seja escoada. Esse volume de água escoada recebe o nome de vazão vertida, é representada pela variável v , medida em m^3/s .

Toda água que chega ao reservatório é chamada de vazão afluente, esta por sua vez é dividida em: vazão incremental e vazão natural. A vazão incremental afluente, representada pela variável y , é o volume de água existente no manancial que advém do reservatório à montante. Esse volume não é medido diretamente, mas calculado pela equação 2.3. A vazão natural, y_n , é a água que aflui naturalmente até o reservatório i sem a interferência ou retenção da água de algum reservatório à montante [13].

$$y_i = y_{n,i} - \sum_{k \in \Omega_i} y_{n,k} \quad [\text{m}^3/\text{s}] \quad (2.3)$$

onde Ω_i conjunto das usinas imediatamente à montante da usina i .

A vazão turbinada, representada pela variável q , é o volume de água que flui pelo conduto forçado, passando pelas turbinas e gerando energia. A vazão turbinada possui limites mínimos e máximos que são denominados, respectivamente, engolimento mínimo e máximo. O engolimento máximo está associado à geração de potência máxima da turbina. A quantidade de água que é devolvida ao rio saindo do reservatório é chamada vazão defluente, u , que é a soma da vazão turbinada e vertida, v , como visto na equação 2.4 [13].

$$u = q + v \quad [\text{m}^3/\text{s}] \quad (2.4)$$

O volume do reservatório é representado por uma função chamada cota à montante, $\Phi(x)$, e no Brasil costuma-se adotar funções polinomiais de até quarto grau para representá-la, sendo os valores dos coeficientes obtidos através de estudos topográficos da região alagada. A cota de jusante do canal de fuga, $\theta(u)$, também é representada por uma função polinomial. A partir dessas duas cotas podemos definir a altura de queda bruta, h_b , equação 2.5. Uma das variáveis envolvidas no cálculo da potência gerada por uma usina é altura de queda líquida, h_l e para o cálculo dela, equação 2.6, é necessário o valor da perda de carga hidráulica [13].

$$h_b = \phi(x) - \theta(u) \quad [\text{m}] \quad (2.5)$$

$$h_l = \phi(x) - \theta(u) - pc \quad [\text{m}] \quad (2.6)$$

A variável pc , medida em metros, representa a perda de carga hidráulica que é a dissipação da energia, devido ao transporte do líquido dentro do canal de adução. A representação mais comum da perda de carga nas usinas brasileiras é a da equação 2.7.1, onde uma constante é multiplicada por uma porcentagem da altura bruta, mas também há outras duas formas de calcular a perda de carga, como visto nas equações 2.7.2 e 2.7.3, uma em função do quadrado da vazão turbinada e outra apenas uma constante [13].

$$pc = \begin{cases} c.h_b & (1) \\ c.q^2 & (2) \\ c & (3) \end{cases} \quad [\text{m}] \quad (2.7)$$

Uma vez conhecidas as variáveis envolvidas na formulação da geração hidrotérmica, na próxima seção encontram-se as equações do problema de coordenação hidrotérmica.

Formulação do problema de coordenação hidrotérmica

O problema de coordenação hidrotérmica pode ser formulado pela equação 2.8 [1]:

$$\min \sum_{t=1}^T \left[\lambda_t \cdot \sum_{j=1}^J \psi_j (g_{j,t}) \right] \quad (2.8)$$

sujeito a:

$$D_t = G_t + P_t$$

$$G_t = \sum_{j=1}^J g_{j,t}$$

$$P_t = \sum_{i=1}^I p_{i,t}$$

$$g_j^{min} \leq g_{i,j} \leq g_j^{max}$$

$$p_{i,t} = k_i h_{i,t} q_{i,t}$$

$$h_{i,t} = \phi(x_{i,t}^{med}) - \theta(u_{i,t}) - pc_{i,t}$$

$$u_{i,t} = q_{i,t} + v_{i,t}$$

$$q_{i,t}^{min} \leq q_{i,t} \leq q_{i,t}^{max}(h_{i,t}), \quad \forall t$$

$$v_{i,t} \geq 0$$

$$x_{i,t}^{med} = \frac{x_{i,t} + x_{i,t}}{2}$$

$$x_{i,t} = x_{i,t-1} + \left(y_{i,t} + \sum_{k \in \Omega_j} u_{k,t} - u_{i,t} \right) \cdot \frac{\Delta t}{10^6}$$

$$x_{i,t}^{min} \leq x_{i,t} \leq x_{i,t}^{max}, \quad \forall t$$

$$u_{i,t}^{min} \leq u_{i,t} \leq u_{i,t}^{max}, \quad \forall t$$

$$\lambda_t = \frac{1}{(1+r)^t}$$

onde:

Variável	Descrição	Unidade
t	Número de intervalos de tempo	
I	Número de usinas hidrelétricas	
J	Número de usinas termelétricas do sistema	
λ_t	Fator de desconto para o intervalo t	
k_i	Produtibilidade específica da usina i	$\frac{MW - \text{médio}}{(m^3 / s).m}$
$\Psi_j(.)$	Função custo da usina termelétrica j	\$
$g_{i,t}$	Geração de energia da usina termelétrica j durante o intervalo t	MW-médio
G_t	Geração de energia termelétrica total durante o intervalo t	MW-médio
P_t	Geração de energia hidrelétrica total durante o intervalo t	MW-médio
D_t	Carga própria a ser atendida durante o período t	MW-médio
g_j^{min}	Geração mínima da usina térmica j	MW-médio
g_j^{max}	Geração máxima da usina térmica j	MW-médio
$x_{i,t}$	Volume armazenado no reservatório da usina i final do intervalo t	hm ³
$x_{i,t}^{med}$	Volume médio do reservatório i durante intervalo t	hm ³
$x_{i,t}^{max}$	Volume máximo do reservatório i durante intervalo t	hm ³
$x_{i,t}^{min}$	Volume mínimo do reservatório i durante intervalo t	hm ³
$h_{i,t}$	Altura de queda líquida	m
$pc_{i,t}$	Perda de carga hidráulica da usina i durante o intervalo t	m
$u_{i,t}$	Vazão defluente da usina i durante o intervalo t	m ³ /s
$q_{i,t}$	Vazão turbinada da usina i durante o intervalo t	m ³ /s
$v_{i,t}$	Vazão vertida pela usina i durante o intervalo t	m ³ /s
$y_{i,t}$	Vazão incremental (lateral) afluyente à usina i durante o intervalo t	m ³ /s
$\phi_i(x)$	Polinômio de cota montante do reservatório da usina i	m
$\theta_i(u)$	Polinômio da cota jusante do canal de fuga da usina i	m
Δt_t	Duração do intervalo t	s
Ω_i	Conjunto de usinas imediatamente à montante da usina i	

A partir da descrição do problema da programação da geração e das numerosas variáveis necessárias para sua solução, nota-se que este não é um problema trivial. A utilização de algoritmos computacionais se faz indispensável para que se encontre uma solução economicamente viável. Dentre eles, diversas meta-heurísticas podem auxiliar na solução desse problema. Sendo assim, o Capítulo 3 fará uma descrição das meta-heurísticas que foram utilizadas para solucionar o problema da coordenação hidrotérmica em [1], assim como das que serão aplicadas nessa dissertação (estratégias evolutivas e recozimento simulado adaptativo difuso) sobre o ponto de vista dos parâmetros de controle.

Capítulo 3

Meta-heurísticas

3.1 - Introdução

Os problemas de otimização possuem como objetivo encontrar uma solução ótima ou próxima dela para um dado problema que, em geral, pode ser resolvido de modo exato ou heurístico. Heurísticas são métodos que buscam a melhor solução possível para um determinado problema, mas não garantem que a solução encontrada é ótima. Com o objetivo de melhorar o desempenho de heurísticas clássicas, surgiu em meados da década de 80 uma nova categoria de métodos que se dedicam a resolver problemas de otimização combinatória, no qual as heurísticas clássicas não produziam soluções satisfatórias: as meta-heurísticas [23].

Meta-heurísticas são heurísticas desenvolvidas para pesquisar no espaço de busca uma solução ótima, ou bem próxima da ótima, em problemas de otimização. Estas possuem algumas características que merecem destaque: são algoritmos aproximados, podem possuir mecanismos que evitem os mínimos locais, exploram eficientemente o espaço de busca, não são específicas para um tipo de problema, entre outras [23, 24].

Nas próximas sessões serão descritas as histórias de alguns algoritmos evolutivos que são meta-heurísticas que usam o conceito de evolução para a solução dos problemas aos quais são submetidos. Após esse pequeno histórico, serão descritas sobre a ótica do controle de parâmetros as meta-heurísticas que serão utilizadas na presente dissertação e as utilizadas em [1].

3.2 - História

No ano de 1957, G. E. P. BOX usou o conceito de operações evolutivas, em [25], descrito como um modo de operação no qual o processo de crescimento da produtividade estava embutido. A filosofia era usar um processo que gerasse além do produto, informações sobre a forma de melhorá-lo, com objetivo de elevar a produtividade de uma indústria.

Em 1958, R. M. FRIEDBERG em [26], propõe um programa computacional que é gradualmente melhorado pelo processo de aprendizado, cujas escolhas eram feitas a partir de instruções, visando associação a resultados bem sucedidos. Em 1962, H. J. BREMERMANN conclui em [27] que a evolução em processos de muitas gerações é fundamental para que se usem as vantagens da seleção.

Na década de 60, surgiram três importantes tipos de algoritmos evolutivos: a programação evolutiva, o algoritmo genético e as estratégias evolutivas.

Em 1962, L. J. FOGEL, buscando resolver problemas de predição do comportamento de máquinas de estado finito, inventou a programação evolucionária. No ano de 1966 lançou com A. J. OWENS e M. J. WASH o livro "*Artificial Intelligence Through Simulated Evolution*" [28], que se tornou importante para aplicações de programação evolutiva.

No mesmo ano, J. H. HOLLAND envolvido com o desenvolvimento de sistemas adaptativos robustos criou o algoritmo genético. Em [29] discute sobre a adaptação através de procedimentos nas gerações e nas populações e a continuidade desses procedimentos que levem as gerações em uma direção promissora. Em 1975 lançou o livro, que hoje é considerado referência em algoritmo genético, "*Adaptation in Natural and Artificial Systems*" [30].

As estratégias evolucionárias foram criadas por I. RECHENBERG e H. P. SCHWEFEL que estavam envolvidos com estudos relacionados à aerodinâmica e tinham como objetivo otimizar formas com foco em questões técnicas como, por exemplo, diminuição de arrasto. Como não conseguiram sucesso utilizando as técnicas tradicionais de otimização, passaram a fazer pequenas modificações aleatórias em todas as variáveis do problema ao mesmo tempo, a princípio sem o uso de computador e para problemas discretos. Esse modo novo de lidar com problemas multimodais foi o início do que hoje é conhecido como estratégia evolutiva, que ao longo dos anos foi modificada até atingir a formulação conhecida atualmente.

Os três algoritmos evolutivos citados possuem algumas características que devem ser destacadas. Os algoritmos genéticos geralmente são utilizados para otimização discreta e para resolução de problemas combinatoriais enquanto as estratégias evolutivas e programação evolutiva são aplicadas principalmente para otimização contínua [31].

A representação dos indivíduos na programação evolutiva e nas estratégias evolutivas são geralmente vetores de valores reais, já no algoritmo genético é comumente *string* binária, o que não impede uma representação com valores reais. A recombinação é o principal operador do algoritmo genético, enquanto programação evolutiva não possui recombinação.

Outra característica que merece destaque é a auto-adaptação dos passos de mutação existente nas estratégias evolutivas e em uma das variações da programação evolutiva. A forma de seleção de uma geração para outra é diferente para cada meta-heurística: em algoritmo genético para a próxima geração todos os filhos gerados substituem os pais, na programação evolutiva há uma escolha na população temporária de pais e filhos, e nas estratégias evolutivas a escolha dos indivíduos que vão compor a próxima geração pode ser escolhida dentro da população temporária composta por filhos e pais ou exclusiva de filhos.

Nas próximas seções serão descritas as meta-heurísticas que foram aplicadas ao problema a ser analisado nessa dissertação: as estratégias evolutivas e o recozimento simulado adaptativo difuso. Algoritmos genéticos, enxame de partículas e recozimento simulado também são descritos, pois foram implementados em [1] e os resultados encontrados são utilizados na presente dissertação como base comparativa de dados.

Essas meta-heurísticas possuem importantes características que motivaram a implementação das mesmas. As estratégias evolutivas, os algoritmos genéticos e o enxame de partículas possuem características comuns como não necessitarem de informações como condições de continuidade, derivadas das funções a serem analisadas, pois utilizam como forma de avaliação uma função objetivo. O recozimento simulado é utilizado para a solução de problemas no sistema de potência, como expansão de redes, despacho econômico e também na coordenação hidrotérmica. Já o recozimento simulado adaptativo difuso foi escolhido pela adaptatividade dos seus parâmetros de busca, além de uma ampla exploração do espaço de busca, bem como as estratégias evolutivas.

Cada meta-heurística possui um conjunto de diferentes parâmetros a serem ajustados que conduz o curso da busca pela melhor solução. O valor de cada um desses parâmetros deve ser cuidadosamente escolhido de acordo com cada algoritmo. No entanto, comumente há dificuldade de encontrar os melhores ajustes. Com isso, alguns modos de ajuste de parâmetros foram encontrados para as diferentes meta-heurísticas na literatura [31]. Portanto, na próxima seção descreveremos as meta-heurísticas citadas sobre a ótica do ajuste dos parâmetros da busca.

3.3 - Controle de Parâmetros

O modo mais simples de se determinar os valores dos parâmetros de uma meta-heurística é também o mais ineficiente. Geralmente, um conjunto de testes preliminares é realizado a fim de determinar esses valores que, uma vez escolhidos, não são modificados até o final da execução do algoritmo. Esses parâmetros freqüentemente são ajustados independentemente, visto que o tempo necessário para a obtenção desses valores é

comumente alto e oneroso computacionalmente. Como consequência, não há correlação entre os parâmetros ajustados, o que acarreta resultados sub-ótimos [32].

A busca pelo melhor modo de ajustar os valores dos parâmetros tem sido alvo de vários estudos [32], [33], [34], mas um fato é sempre tido como necessário: os parâmetros não devem ser fixos para se obter melhores resultados, ou seja, os valores dos parâmetros devem variar durante a execução do algoritmo. O ajuste de parâmetros pode ser dividido em: parâmetros fixos e controle de parâmetros. Já o controle de parâmetros é subdividido em: controle de parâmetros determinístico, adaptativo e auto-adaptativo, como visto na figura 3.1.

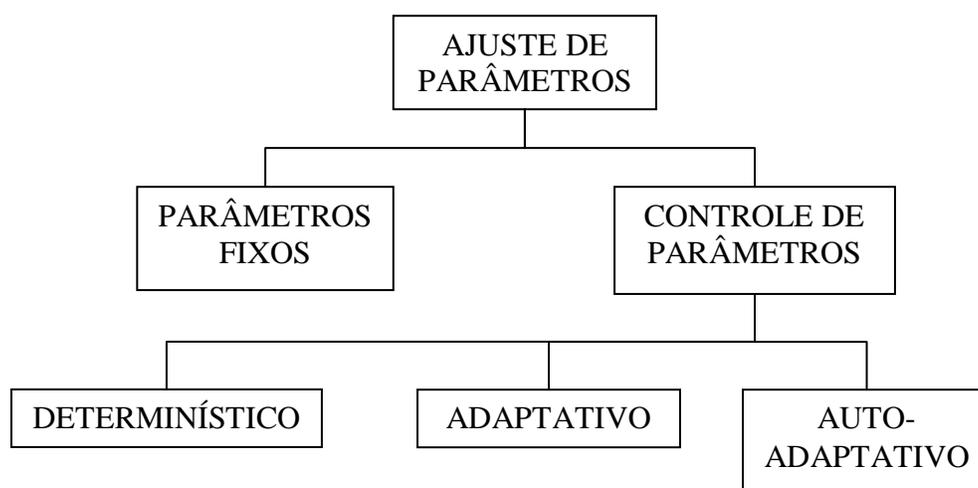


Figura 3.1 – Classificação do ajuste de parâmetros

Nas subseções 3.3.1, 3.3.2, 3.3.3 e 3.3.4, serão descritos como cada um desses ajustes de parâmetros se aplica as meta-heurísticas utilizadas nessa dissertação e em [1].

3.3.1 – Parâmetros Fixos

O algoritmo genético é um exemplo de meta-heurística que comumente não utiliza controle de parâmetros, ou seja, utiliza ajuste de parâmetros fixos. O tamanho da população, a taxa de recombinação e de mutação, que serão descritos a seguir, são ajustados antes da execução do algoritmo e não se modificam até o seu término, fazendo com que os resultados sejam altamente dependentes do ajuste.

A seguir, uma descrição dos algoritmos genéticos será exposta, explicando seu algoritmo básico e os mecanismos utilizados na busca da melhor solução.

Algoritmo Genético

Os algoritmos genéticos correspondem à classe de meta-heurísticas que usam o conceito da evolução e da genética, e foram desenvolvidos por John Holland na década de 60, onde o principal dado necessário é a função adequabilidade que será avaliada pelo algoritmo. Os algoritmos genéticos são implementados em vários tipos de busca, de otimizadores, para solução de problemas de programação entre outras aplicações.

Em linhas gerais, o algoritmo parte de uma população inicial que a cada geração passa por operadores genéticos e pela avaliação da função adequabilidade, com o objetivo de encontrar a melhor solução para a função objetivo em questão, dentro do critério de parada estabelecido, como pode ser visto na figura 3.2.

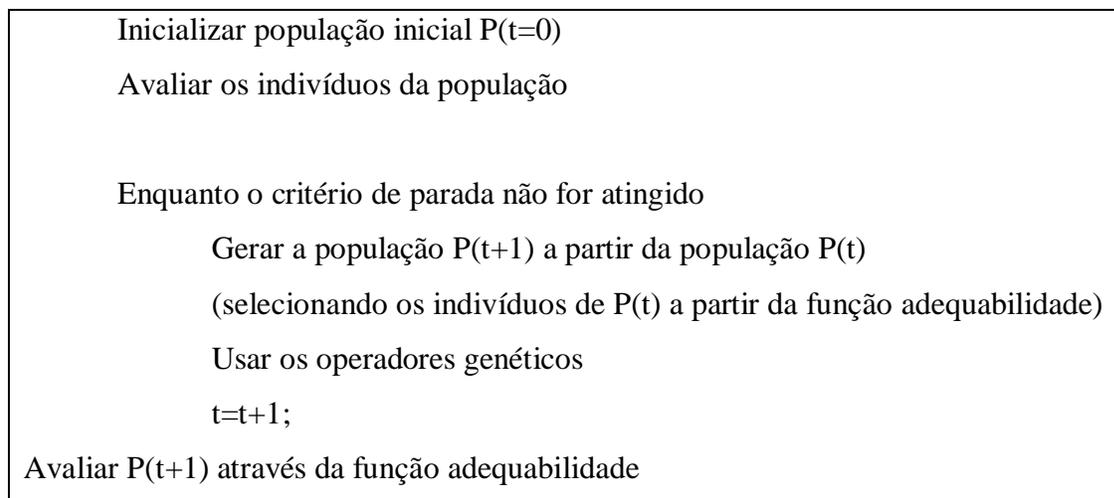


Figura 3.2 - Pseudo código de algoritmo genético.

A população inicial é formada por um conjunto de indivíduos, correspondentes a possíveis soluções, que possuem probabilidades de serem alterados em busca de uma melhor solução. A população é geralmente inicializada aleatoriamente, e em muitos casos

utiliza heurísticas para isso, e é posteriormente alterada pelos operadores genéticos: cruzamento, mutação e seleção.

O cruzamento consiste na recombinação entre os indivíduos, geralmente dois, que geram dois novos indivíduos. É o principal operador, pois gera diversidade na população e por isso é aplicado com alta probabilidade. As técnicas de recombinação mais utilizadas são a de um ponto, de dois pontos e a uniforme. No caso da recombinação de um ponto, um ponto é sorteado e a partir daquele ponto, há troca de material genético entre os dois pais (Figura 3.3), no de dois pontos, dois pontos são sorteados para ser ponto de troca de genes, nesses casos são gerados dois filhos (Figura 3.4). No cruzamento uniforme há a troca de todos os genes entre dois pais para a geração de um único filho (Figura 3.5).

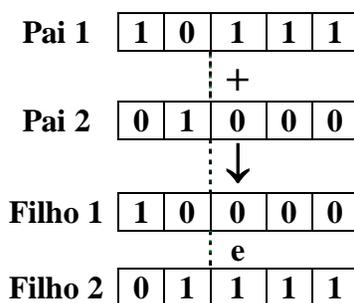


Figura 3.3 - Cruzamento de um ponto

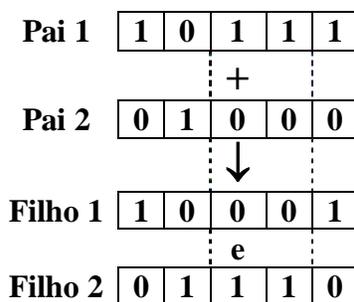


Figura 3.4 - Cruzamento de dois pontos

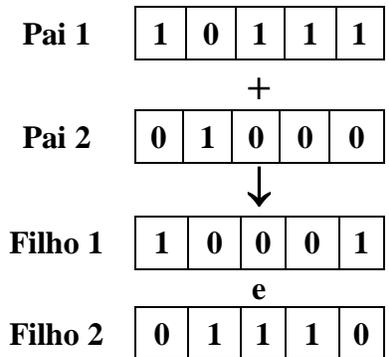


Figura 3.5 - Cruzamento Uniforme

A mutação inclui um novo elemento na população a partir da alteração aleatória de um ou mais genes de um ou mais indivíduos, como mostra a figura 3.6. A quantidade de genes a ser alterada é determinada por uma taxa, conhecida como taxa de mutação.

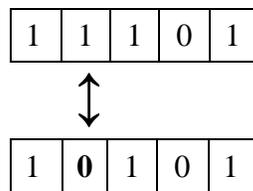


Figura 3.6 - Esquema mutação.

Em geral, a codificação utilizada em algoritmos genéticos é a binária, mas também se pode utilizar a representação real, ou seja, os valores dentro dos genes são números reais. Com a codificação real, o modo de mutação do gene acontece pela substituição por outro valor, através de um valor gerado aleatoriamente ou pela perturbação do valor inicial, somando a ele um ruído gerado a partir de uma distribuição, por exemplo, a gaussiana, figura 3.7 e as equações 3.1 e 3.2.

$$x_i' = x_i + N(0, \sigma) \tag{3.1}$$

$$x_i' = x_i + n \text{ onde } n \text{ é um valor real.} \tag{3.2}$$

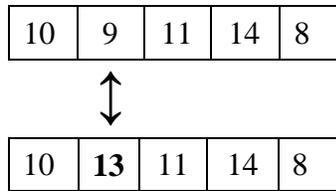


Figura 3.7 - Esquema mutação.

Após a mutação, a população sofre a ação da seleção. Existem várias técnicas para seleção dos indivíduos para a próxima geração, sendo algumas dessas técnicas: seleção proporcional, por torneio, por ordenação e a elitista.

A seleção proporcional consiste em dar uma probabilidade a cada indivíduo da população. Os melhores indivíduos, segundo a avaliação da função de adequabilidade, terão maiores probabilidades e com isso maiores chances de seleção para a próxima geração. A probabilidade que é dada a cada indivíduo é descrita pela equação 3.3, [1] e a tabela 3.1, ilustra esse tipo de seleção.

$$P_i = \frac{F(x_i)}{\sum_{i=1}^P F(x_i)} \quad , \quad (3.3)$$

onde :

P_i = probabilidade de seleção do indivíduo x_i ;

P = número do indivíduo da geração;

F = função adequabilidade.

Tabela 3.1 – Modo de seleção proporcional.

indivíduos	Valor da função adequabilidade	Calculo de P_i	P_i (%)
ab	20	20/50	40
AB	15	15/50	30

Ab	10	10/50	20
aB	5	5/50	10
Total =>	50		100

A seleção por torneio consiste em escolher aleatoriamente k indivíduos e selecionar o melhor indivíduo entre os k , repetindo n vezes o processo até atingir o número de indivíduos para a próxima geração. O valor de k mínimo é 2. Na tabela 3.2, um exemplo desse tipo de seleção para a população na tabela 3.1, de 4 indivíduos, onde $k=2$. Na primeira coluna estão os 4 indivíduos, na segunda as n seleções com k indivíduos em cada uma delas e na terceira coluna a nova população.

Tabela 3.2 - Modo de seleção torneio.

População Inicial	Seleção aleatória de 2 indivíduos	Nova população
Ab	(1) ab e Ab	Ab
AB	(2) AB e aB	AB
Ab	(3) ab e Ab	Ab
ab	(4) Ab e aB	Ab

A seleção por ordenação consiste na ordenação dos indivíduos avaliados pela função adequabilidade. Essa seleção se subdivide em: seleção truncada, por ordenação linear e por ordenação exponencial. Na seleção truncada, os melhores indivíduos participam de um sorteio no qual cada um tem a mesma probabilidade de ser sorteado; na seleção por ordenação linear, a probabilidade de sorteio é inversamente proporcional ao número de ordem; e na seleção por ordenação exponencial, a ponderação de cada indivíduo é uma função exponencial [1].

A seleção elitista consiste em replicar um pequeno número ou porcentagem de indivíduos na população da geração seguinte enquanto os demais indivíduos para a próxima geração são escolhidos por outro método de seleção.

3.3.2 – Controle de Parâmetro Determinístico

O controle de parâmetros determinístico consiste em alterar o valor do parâmetro por meio de uma regra determinística. A regra é determinada previamente pelo usuário e não leva em consideração nenhum resultado obtido pelo algoritmo. Geralmente o novo valor do parâmetro é dado por uma regra dependente do tempo, por exemplo, o número de gerações do algoritmo.

O Recozimento Simulado é um dos algoritmos que utiliza controle de parâmetro determinístico. Como será descrito, os principais parâmetros são definidos e são fixos até o final do processo. No entanto, com o decorrer das transições alguns parâmetros que dependem do número de transições se modificam devido a uma regra, vale salientar que essa mudança não utiliza nenhum resultado encontrado pelo recozimento simulado.

Recozimento Simulado

O recozimento simulado é uma técnica poderosa para solucionar problemas e já é utilizada na área do sistema de potência. Tem como inspiração a metalurgia, onde a temperatura do material é elevada ao máximo possível e diminuída lentamente até que atinja um estado de energia mínima e com isso atinja a cristalização perfeita.

O algoritmo escolhe ao acaso uma solução inicial (x_0), chamada estado inicial, para uma temperatura inicial (T_0). Uma próxima solução, chamada próximo estado, é formada a partir da perturbação (ϵ) do valor do estado anterior. Essa solução mudará se a próxima solução, próximo estado, tiver um estado de energia menor, equivalente a encontrar um custo menor. Se a próxima solução tiver uma energia maior do que a anterior, ou seja, um custo maior, uma probabilidade (q) é utilizada para determinar se esse novo estado será aceito ou não. Esse processo se repete até o número de transições (N) de estados dentro de uma dada temperatura for atingido [35].

Após o número de transições ser atingido, a temperatura se reduz e todo o procedimento anterior é repetido. A quantidade de vezes que a temperatura (T) se reduz é dada por K . Todo esse processo se repete até atingir o critério de parada. Os critérios de parada são: número de reduções de temperatura, estagnação da solução ou número máximo de estados de energia menor a serem aceitos. Para o sucesso do algoritmo, os quatro parâmetros principais da busca devem ser bem ajustados. Esses parâmetros são: temperatura inicial (T_0), número de transições (N), número de reduções de temperatura (K) e valor da perturbação (ϵ).

Na figura 3.8 encontra-se o pseudocódigo básico do recozimento simulado, onde podemos perceber que a escala de temperatura modifica-se durante o processo baseada em uma regra determinística, no entanto, como salientado não utiliza nenhum resultado obtido durante o processo do algoritmo.

```

Inicializar ( $T_0, N, K, \epsilon$ )
Selecionar uma solução inicial ( $x_0$ )
Avaliar  $f(x_0)$ 
Até atingir  $K$  (um dos critérios de parada)
     $n = n + 1$ 
     $x_j = x_i + \epsilon \cdot N(0, 1)$ ;
    Se  $f(x_j) < f(x_i)$ 
        Então  $x_i := x_j$ 
    Senão
         $q = N(0, 1)$ 
        Se  $q < \exp \{ [(f(x_j) - f(x_i)) / T] \}$ 
            Então  $x_i := x_j$ 
    Se resto  $n/N = 0$ 
         $t = t + 1$ ;
         $T_k = T_0 / \log_2(1 + t)$ ;

```

Figura 3.8 - Pseudocódigo Recozimento Simulado Básico.

3.3.3 - Controle de Parâmetro Adaptativo

No controle de parâmetros adaptativo durante o processo de busca pela solução, algumas informações dos resultados gerados pelo algoritmo são utilizadas para determinar a mudança de um ou mais parâmetros durante as iterações. É importante notar que, embora a mudança seja baseada em dados provenientes dos resultados obtidos pelo próprio algoritmo, o mecanismo de controle dos parâmetros ainda é determinado por alguma regra externa ao algoritmo, ou seja, não é governada pelas regras evolucionárias.

Um bom exemplo de controle adaptativo é o algoritmo evolutivo enxame de partículas. Como será descrito a seguir, o parâmetro velocidade de deslocamento (v_i) é influenciado por G_{best} e P_{best} (melhor indivíduo e melhor avaliação de um dado indivíduo). Portanto, o enxame de partículas utiliza seu próprio resultado para controlar um de seus parâmetros.

Outro exemplo de controle adaptativo é o recozimento simulado adaptativo difuso. Esse é um algoritmo de múltiplas entradas e uma saída, onde informações obtidas na amostragem da saída são utilizadas para realizar ações corretivas de acordo com regras pré-estabelecidas. Essa meta-heurística também será descrita nessa subseção.

Ainda podemos citar as estratégias evolutivas na versão (1+1)-EE, na qual a variação dos desvios padrões, utilizados na gaussiana responsável na perturbação na mutação, era decidida a partir da regra de sucesso de 1/5, como será visto na seção 3.3.4, equação 3.1.5.

Enxame de Partículas

O enxame de partículas originou-se das pesquisas sobre o comportamento de enxames de algumas espécies de animais e no desejo da modelagem dos mesmos. No ano de 1985, em [36], R. BOYD e P. RECHARSON, após estudos de aprendizagem individual e transmissão cultural, concluem que experiências, individuais ou de terceiros, quando compartilhadas exercem influência sobre decisões de um dado indivíduo [1].

Craig REYNOLDS, em 1986, desenvolveu o sistema *boid* que é um conjunto de regras que descreve o comportamento do enxame, tendo por objetivo, para cada indivíduo:

- 1) afastar-se do indivíduo mais próximo;
- 2) ir em direção ao destino;
- 3) ir em direção ao centro do enxame.

O biólogo Frank HEPPNER, fez uma simulação de um bando de pássaros procurando abrigo, onde os pássaros começavam voando ao acaso e aos poucos iam formando o bando. Após a formação do bando cada pássaro evitava colidir com os pássaros mais próximos e procurava estar no meio dos pássaros vizinhos, até que um pássaro encontrava abrigo para pouso, fazendo com que o restante do bando, aos poucos, pousasse também.

A técnica de otimização baseada em enxame de partículas foi criada no ano de 1995 por Russ EBERHART e James KENNEDY, em [37], que tiveram como base trabalhos anteriores e com forte influência do trabalho de HEPPNER. Essa técnica consiste em uma otimização estocástica com base no comportamento individual e social da população [1].

O algoritmo original foi modificado, como no ano de 1998 quando EBERHART e SHI, em [38], incluíram os chamados parâmetros de confiança, que indicam o quanto um dado indivíduo confia em si próprio e no restante da população. Em 2004, RATNAWEERA, HALGAMUGE e WATSON, em [39], propuseram equações para que esses parâmetros variassem a cada iteração.

Pseudo código

O algoritmo, figura 3.9, gera aleatoriamente sua população inicial que é avaliada pela função adequabilidade. O melhor valor atingido (globalmente), bem como o melhor valor atingido por cada indivíduo (particularmente) serão guardados a cada iteração, pois eles determinarão o valor da velocidade de deslocamento do indivíduo, o que determinará a nova posição do mesmo.

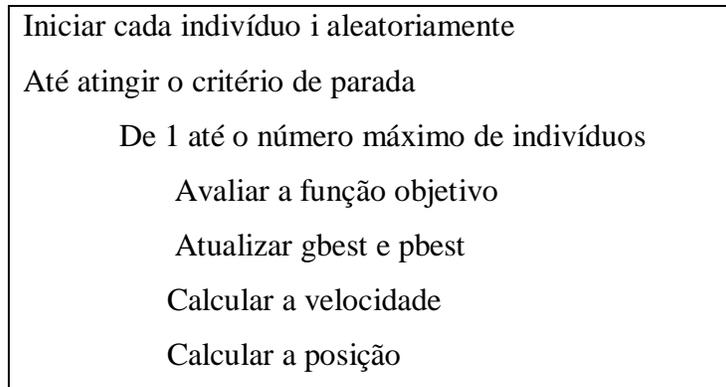


Figura 3.9 - Pseudocódigo do enxame de partículas.

A população inicial consiste em soluções aleatórias que serão avaliadas a cada geração. As soluções em potencial se distribuem através do espaço de solução e seguem a melhor solução naquela geração. A cada geração dois valores ótimos são observados:

- 1) Gbest: é o melhor indivíduo da população até a iteração em questão. Esse valor representa transmissão cultural da população influenciando na decisão do indivíduo.
- 2) Pbest: é a melhor avaliação de um dado indivíduo até a iteração em questão. Esse valor representa o conhecimento individual adquirido pelo indivíduo.

Esses valores terão influência na velocidade de deslocamento v_i de cada indivíduo que se move no espaço de busca descrita pela equação 3.4.

$$V^{k+1} = v_i^k + \underbrace{c_1 * rand_1(pbest_i - x_i^k)}_{\text{aprendizado individual}} + \underbrace{c_2 * rand_2(gbest - x_i^k)}_{\text{comportamento social}}. \quad (3.4)$$

onde

v_i^k representa a velocidade atual do indivíduo i;

c_1 e c_2 parâmetros de confiança;

$rand_1$ e $rand_2$ funções aleatória de valor entre 0 e 1;

x_i^k posição onde o indivíduo i se encontra na iteração k.

Os parâmetros de confiança possuem valores típicos. SHI e EBERHART [38] sugeriram que os dois parâmetros assumissem valor igual a 2 [1], [40]. Já RATNAWEERA *et al* [39] sugere equações que são atualizadas a cada iteração. A mudança da posição de cada indivíduo se dá pela equação 3.5.

$$X_i^{k+1} = x_i^k + V_i^{k+1} . \quad (3.5)$$

Variações do algoritmo enxame de partículas

Algumas modificações foram propostas ao longo dos anos ao método de exame de partículas, sendo que as mais relevantes foram: o limitador de velocidade, componente inercial e o fator de constrição.

Limitador de velocidade

Para um melhor controle da velocidade de deslocamento do indivíduo foi criado o limitador de velocidade, que determina a velocidade máxima dos indivíduos.

Componente inercial

A componente inercial, w , foi criada com o objetivo de auxiliar na convergência nas últimas iterações, por SHI e EBERHART em [38]. Essa componente é multiplicada ao valor da velocidade atual do indivíduo i , como visto na equação 3.6.

$$V_i^{k+1} = w * v_i^k + c_1 * \text{rand}_1(\text{pbest}_i - x_i^k) + c_2 * \text{rand}_2(\text{gbest} - x_i^k). \quad (3.6)$$

Esse parâmetro deveria também segundo os autores variar. Inicializando em um valor elevado (efeito de busca global) e diminuir gradualmente até atingir um valor pequeno (efeito de busca local), permitindo uma convergência com um número menor de iterações. Sendo assim, sugeriram o valor da componente inercial entre 0,9 e 0,4 com variação linear com o número de iterações (gerações), como descrito na equação 3.7 [1].

$$W = w_{\max} - [(w_{\max} - w_{\min}) / k_{\max}] * k, \quad (3.7)$$

onde:

$w_{m\acute{a}x}$ - valor inicial;

$w_{m\acute{i}n}$ - valor final;

$k_{m\acute{a}x}$ - numero maximo de geraoes;

k - numero da geraao corrente.

Fator de constricao

Em 2002, CLERC e KENNEDY em [41], criaram o fator de constricao χ que funciona no controle dos valores das velocidades. Quando esse fator  baixo a convergencia  rapida, mas nao necessariamente de boa qualidade e, ao contrario, h maior exploraao do espao de busca [40].

$$V_i^{k+1} = \chi * v_i^k + c_1 * \text{rand}_1(\text{pbest}_i - x_i^k) + c_2 * \text{rand}_2(\text{gbest} - x_i^k), \quad (3.8)$$

onde:

$$\chi = 2k / |2 - \varphi - \sqrt{(\varphi - 4)\varphi}|;$$

$$\varphi = c_1 + c_2;$$

$$\varphi \geq 4.$$

Recozimento Simulado Adaptativo Difuso

Para melhor entendimento da meta-heurstica recozimento simulado adaptativo difuso, faz-se necessario uma breve explicaao da meta-heurstica recozimento simulado adaptativo e da logica difusa, como ser detalhado a seguir.

Recozimento Simulado Adaptativo

Apos a criaao do recozimento simulado padrao, outros algoritmos surgiram com o mesmo princpio, porm com modificaoes na escala de temperatura com o objetivo de diminuir o tempo de execuao. O *Simulated Quenching*  um exemplo, ele substituiu o

cronograma de temperatura Boltzman por um cronograma de temperatura logarítmica. O recozimento rápido, *fast annealing*, utiliza um novo cronograma de temperatura usando a distribuição de Cauchy, que faz com que o algoritmo possua uma escala de recozimento exponencialmente mais rápida do que o método clássico.

No entanto, há problemas em um espaço n-dimensional onde os cronogramas de recozimento necessitam de variações diferentes, ou seja, que elas sejam sensíveis a cada dimensão. Essa sensibilidade não era possível nos algoritmos já citados e, para tal, surgiu o recozimento simulado super rápido, atualmente conhecido como recozimento simulado adaptativo.

Tabela 3.3 - Tabela de cronograma de recozimento.

Método de recozimento simulado	Cronograma de recozimento
Boltzman (padrão)	$T=T_0/\ln k$
<i>Simulated Quenching</i>	$T=T_0 (\ln k_0)/ (\ln k)$
Rápido	$T = T_0 / k$
Adaptativo	$T= T_0 \exp (-c k^{1/D})$

Onde:

T_0 = temperatura inicial;

k_0 = escala de tempo do recozimento inicial (escala *annealing*);

k = escala de tempo do recozimento (escala *annealing*);

c = parâmetro definido pelo usuário;

D = número de dimensões.

O recozimento simulado adaptativo [42] é um algoritmo de otimização global que possui essa sensibilidade e considera a dimensão em seu cronograma de recozimento. Duas características importantes existentes no algoritmo são o *reannealing* e o *quenching*.

O *reannealing* consiste em reescalar a escala de tempo de recozimento k , a cada intervalo decidido pelo usuário em termos de sensibilidade, calculando a derivada parcial da função custo em relação ao melhor indivíduo aceito até então.

O *quenching* possibilita a modelagem das temperaturas através da introdução do fator de *quenching* Q , que, se possuir valor superior a 1, levará a um ganho de velocidade na busca de uma solução. O cronograma de recozimento passa a ser:

$$T = T_0 \exp(-c k^{Q/D}). \quad (3.9)$$

Vale ressaltar, que o recozimento simulado adaptativo possui alto nível de parametrização, tornando possível ao usuário acessar e modificar alguns parâmetros como: modo de geração de pontos iniciais, comportamento do processo de geração e aceitação de pontos, entre outros.

$$x_{i+1} = x_i + \Delta x_i$$

onde $\Delta x_i = y_i (B_i - A_i)$

$[A_i, B_i]$ = faixa de variação de i -ésima dimensão

$y_i \in [-1, 1]$ é dado por

$$y_i = \text{sgn}(u_i - 1/2) T_i [(1 + 1/T_i)^{2|u_i-1/2|} - 1]$$

onde $u_i \in [0, 1]$ é gerado por uma distribuição uniforme

T_i = temperatura atual relativa à dimensão i

Sgn é um tipo de degrau que devolve como resposta -1, se o argumento for negativo e 1, se for positivo ou nulo.

Figura 3. 10 - Esquema de geração de pontos no recozimento simulado adaptativo.

Lógica Difusa

A lógica difusa é uma área da Matemática que utiliza o conceito de conjuntos e operações difusos, viabilizando a modelagem de sistemas de forma flexível e real. Como exemplos: modelagem de restrições, modelagem de incerteza sem disponibilidade de dados

estatísticos, etc. Um conjunto difuso, equação 3.10, geralmente representa incertezas, informações vagas e ambigüidades como: a definição da transição entre o quente e frio, alto e baixo, etc.

$$\text{Seja então } F = \{(x, \mu_F(x)/x \in U\}, \quad (3.10)$$

onde F é o conjunto difuso que possui como elemento o par ordenado x e função de pertinência associada $\mu_F(x)$, no qual o elemento x pertence ao universo de discurso U .

As funções de pertinência são funções que medem o grau de verdade em uma informação, possuindo como domínio U e como imagem valores entre zero e um, onde zero corresponde a não pertinência ao conjunto difuso em questão e um a pertinência total a esse conjunto. As formas de representação de funções de pertinência mais utilizadas são a trapezoidal, a triangular e a gaussiana. No entanto, qualquer função poderia ser adotada.

Através das funções de pertinência de dois ou mais conjuntos difusos podemos realizar as operações de união, interseção e complemento.

- União:

A operação união dos conjuntos A e B . Corresponde em agregar os conjuntos A e B (3.11), que equivale à operação booleana OR.

$$\mu_{A \cup B} = \max[\mu_A(x); \mu_B(x)]. \quad (3.11)$$

- Interseção:

A operação interseção dos conjuntos A e B . Corresponde a unir as partes comuns dos conjuntos A e B (3.12), que equivale à operação booleana AND.

$$\mu_{A \cap B} = \min[\mu_A(x); \mu_B(x)]. \quad (3.12)$$

- Complemento:

O complemento de A é equivalente ao restante do universo de discurso U, excetuando o conjunto A. Equivale à operação booleana NOT.

$$\mu_A^c = 1 - \mu_A(x). \quad (3.13)$$

Finalizadas as explicações do recozimento simulado adaptativo e da lógica difusa, segue a descrição do recozimento simulado adaptativo difuso.

O recozimento simulado adaptativo difuso [19] é um método que acelera a convergência do recozimento simulado adaptativo através da implementação de um controlador difuso que ajusta os parâmetros que possuem relação com o procedimento *quenching* de forma dinâmica [43]. Para tal existem três elementos que devem ser destacados:

- (1) A densidade de probabilidade $g(\cdot)$, utilizada na geração de novos pontos candidatos.
- (2) A densidade de probabilidade $a(\cdot)$, utilizada na aceitação ou rejeição de novos pontos.
- (3) O cronograma de redução de temperaturas $T(\cdot)$ que determina como elas variarão durante o funcionamento do algoritmo.

O funcionamento do algoritmo pode ser descrito da seguinte forma: geração de um ponto inicial e o ajuste da temperatura inicial, que deve possibilitar a exploração do espaço de busca. Após isso, novos pontos são gerados pela função densidade de probabilidade $g(\cdot)$ e aceitos ou rejeitados de acordo com a função de densidade de probabilidade $a(\cdot)$. Se o ponto é aceito, ele se transforma em ponto básico. Conforme a temperatura é reduzida, diminuem as chances de que um ponto com valor de função objetivo superior ao ponto básico corrente seja aceito. No entanto, mesmo que reduzida, há uma possibilidade de que pontos piores do que o ponto básico vigente sejam aceitos, e nessa situação duas funções existentes no recozimento simulado adaptativo são relevantes: o *reannealing* e o *quenching*, como citado anteriormente. Para ajustar dinamicamente a velocidade de convergência de modo automático (mecanismo de *quenching*), um controlador difuso foi projetado.

O recozimento simulado adaptativo difuso [19] considera o recozimento simulado adaptativo como um sistema de múltiplas entradas e uma saída. A malha fecha pela amostragem da saída e atuação nos parâmetros de entrada. Através da lógica contida no controlador difuso, é possível ajustar os parâmetros de *quenching* em tempo de execução e, com isso, ocorre o aumento ou redução nas taxas de alteração das temperaturas correspondentes às várias dimensões do espaço de busca, possibilitando a fuga da convergência prematura.

As informações obtidas na amostragem da saída informam o estado atual do processo de minimização utilizando o conceito de sub-energia, cuja função é dada por:

$$SE(x, x_0) = \log (1/[1+\exp-(f(x)-f(x_0))-a]), \quad (3.14)$$

onde a é uma constante real e x_0 é o ponto básico corrente

A função $SE(.)$ mantém o comportamento da função original quando o algoritmo passa por pontos melhores que o ponto básico corrente. Quando o algoritmo encontra pontos piores do que os mínimos atuais, a função $SE(.)$ tende a deformar. As regiões já avaliadas têm um achatamento mais suave enquanto as regiões promissoras possuem curvatura mais acentuada. Esse comportamento facilita a avaliação dos pontos assumidos pela função objetivo, através da função sub-energia, possibilitando assim a modelagem difusa, visto que podemos concluir se a busca está próxima ou muito distante do ponto básico atual.

A atuação nas variáveis de entrada pelo controlador difuso, como citado anteriormente, consiste em ações corretivas que atuam de acordo com as regras pré-estabelecidas. Isto está relacionado às funções de densidade de probabilidade de geração e aceitação no que tange à variação dos graus de *quenching*, utilizando fatores individuais de *quenching* para cada dimensão. O controlador difuso possui regras como:

Se Ave Sub está próxima a zero então aumente o nível de *quenching*;
Se Ave Sub está próxima ao mínimo corrente então aumente o nível de *quenching*;
Se StdDevSub é zero então diminua o nível de *quenching*;

Onde

AveSub é uma variável lingüística que corresponde à média aritmética dos cem últimos valores de sub-energia e;

StdDevSub é uma variável lingüística que corresponde ao desvio padrão dos cem últimos valores de sub-energia.

3.3.4 - Controle auto-adaptativo de parâmetros

O controle auto-adaptativo de parâmetros consiste em inserir alguns parâmetros como genes dentro de cada indivíduo da população e, como parte integrante de um indivíduo, eles sofrem a ação de todos os mecanismos evolutivos como, por exemplo, a recombinação, a seleção e a mutação. Deste modo, de acordo com a idéia dos algoritmos evolutivos, os parâmetros com valores mais adequados estarão mais aptos a sobreviver e gerar mais descendentes, propagando esses valores.

As estratégias evolucionárias são o principal exemplo de meta-heurística que utiliza controle auto-adaptativo. As taxas de recombinação, de mutação e o tamanho da população podem ser inseridos como genes, em cada indivíduo da população e 'evoluem', sofrendo os processos de seleção, recombinação e mutação e, assim, determinando o melhor valor de cada parâmetro sem nenhuma regra externa ao algoritmo.

Os algoritmos genéticos também se aplicam nessa categoria de classificação, pois existem alguns estudos com objetivo de substituir o ajuste de parâmetros fixos para o auto-adaptativo. Como exemplo, podemos citar o artigo [33] que, vale ressaltar, foi utilizado nessa dissertação como base para a inclusão de novos parâmetros no algoritmo de estratégias evolutivas, e por isso será descrito.

Estratégias Evolutivas

As estratégias evolutivas foram desenvolvidas na década de 60 na Alemanha, por Ingo Rechenberg e Hans Paul Schwefel, como citado anteriormente e seus criadores fizeram algumas melhorias até atingir a formulação conhecida atualmente.

Esboçada na tese de doutorado de Ingo Rechenberg, no ano de 1971, a primeira versão das estratégias evolutivas era a (1+1)-EE onde um único pai dava origem a um único filho. Após isso, eles eram comparados permanecendo o indivíduo mais apto entre os dois, segundo a função adequabilidade e as restrições existentes no problema. Os indivíduos eram representados por vetores reais e o indivíduo pai era perturbado por uma gaussiana de média zero e desvio padrão σ . Essa perturbação é denominada mutação gaussiana.

No ano de 1973, Rechenberg propôs a adaptatividade para controlar a perturbação da mutação, com isso o desvio padrão faria parte do processo evolutivo seguindo a assim a regra de sucesso 1/5. Essa regra foi criada devido à ineficácia da perturbação gaussiana com desvio padrão fixo. Assim, o desvio padrão era atualizado a cada n iterações seguindo a equação 3.15.

$$\sigma^{t+1} \begin{cases} \frac{\sigma^t}{c} & \text{se } p_n > 1/5 & (1), \\ c\sigma^t & \text{se } p_n < 1/5 & (2), \\ \sigma^t & \text{se } p_n = 1/5 & (3). \end{cases} \quad (3.15)$$

Na amostragem de n iterações, se mais de 20% das mutações fossem bem sucedidas o desvio padrão seguia a equação 3.15.1, que representa um aumento na probabilidade de perturbações maiores. Se menos de 20% das mutações fossem bem sucedidas, c assumia valor menor que 1, na equação 3.15.2. Um valor típico é 0.82 [44], o que representa uma redução do desvio padrão anterior. Caso o número de iterações positivas se igualasse a 20% mantém-se o mesmo desvio padrão utilizado anteriormente, equação 3.15.3.

Rechenberg introduziu a população nas estratégias evolutivas quando criou o $(\mu+1)$ -EE onde μ pais ($\mu > 1$) geravam, através de recombinação e mutação, um único filho que

substituía o pior pai. Essa versão foi pouco explorada por possuir dificuldade de controlar, de um modo eficiente, o desvio padrão da mutação [17].

No ano de 1981, Schwefel introduz múltiplos filhos ao algoritmo, além de incluir nos indivíduos, como gene, o desvio padrão do mecanismo de perturbação. As estratégias passaram a ser denominadas $(\mu+\lambda)$ -EE, μ pais geram λ filhos, e da população temporária de $\mu+\lambda$ indivíduos, são selecionados para a próxima geração μ indivíduos. No entanto, quando esse mecanismo de seleção é aplicado em problemas com superfícies que variam ao longo do tempo, o mecanismo de busca tende a estagnar em mínimos locais [45]. Por isso, Schwefel em 1995, apresentou em [45] as (μ,λ) -EE, onde μ pais geram λ filhos, no entanto, somente da sub-população de λ filhos são selecionados μ indivíduos para a próxima geração.

Atualmente, as estratégias evolutivas são aplicadas principalmente em otimizações numéricas. O pseudocódigo descrito na figura 3.11, em linhas gerais, possui uma população inicial que é determinada aleatoriamente e que sofrerá a ação da recombinação, mutação e seleção, com o objetivo de encontrar a melhor solução para um determinado problema.

```
Inicializar população inicial  $P(t=0)$  com  $\mu$  elementos
Enquanto o critério de parada não for atingido
  Até atingir  $\lambda$ 
    Recombinar os elementos de  $P(t)$  (cada filho gerado por  $\rho$  pais)
    Mutar os elementos  $P(t)$ 
    Calcular a função adequabilidade de cada indivíduo de  $P(t)$ 
  Seleção
    Se  $\mu,\lambda$ 
       $P(t+1)$  = com  $\mu$  elementos selecionados da população  $P(t)$ 
    Se  $\mu+\lambda$ 
       $P(t+1)$  = com  $\mu$  elementos selecionados da população  $P(t)$  e  $P(t-1)$ 
   $t=t+1$ 
```

Figura 3.11 - Pseudocódigo de estratégias evolucionárias.

A seguir estão detalhados os elementos básicos do algoritmo descrito na figura 3.11.

População Inicial

A população inicial é composta por um conjunto de indivíduos que formam o conjunto de possíveis soluções. A população é, geralmente, inicializada aleatoriamente.

Função adequabilidade

A função que avalia cada indivíduo da população à luz da função objetivo e das restrições do problema original. Eventualmente, na ausência de uma função objetivo explícita, a função de adequabilidade é representada por índice de mérito relacionado à simulação.

Recombinação

A recombinação tem como objetivo, através da combinação de dois ou mais indivíduos, formar outro indivíduo, diversificando a população existente e explorando o espaço de busca pelo ótimo global. Os tipos de recombinação mais usados em estratégias evolucionárias são: a recombinação discreta e a intermediária.

A recombinação discreta é a que recombina os indivíduos, escolhendo aleatoriamente um gene de um dos pais para a formação do filho, como ilustrada na figura 3.12.

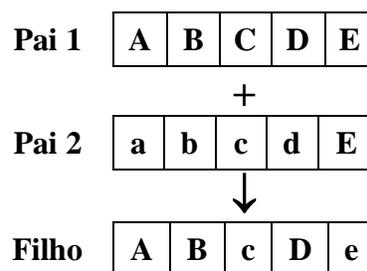


Figura 3.12 - Esquema da recombinação discreta

A recombinação intermediária recombina os indivíduos usando a média de cada gene paterno, como pode ser observado na figura 3.13. Vale ressaltar, que mesmo no caso de mais de dois pais para a geração de um filho, somente os genes dos dois pais escolhidos, aleatoriamente para cada alelo (elemento do código), participam da média para formação do filho, como mostrado na figura 3.14.

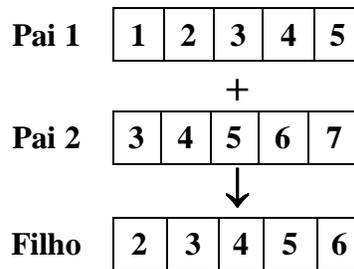


Figura 3.13 - Esquema da recombinação intermediária

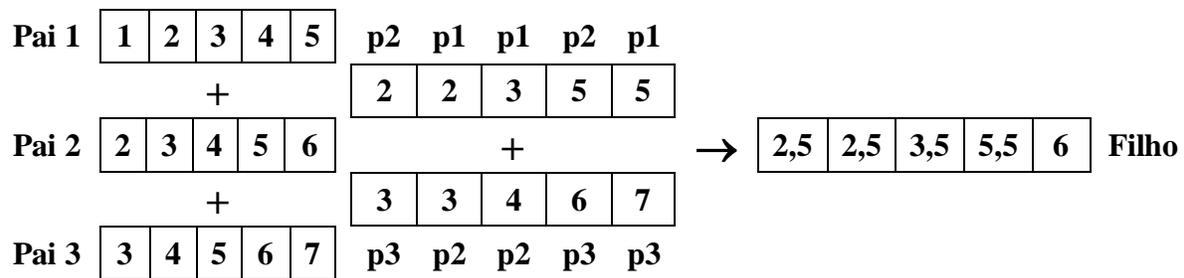


Figura 3.14 - Esquema da recombinação intermediária com mais de dois pais

Há também outros modos de recombinação como a recombinação de um ponto, no qual os pais têm um ponto escolhido e trocam um dos lados formando um novo filho, como mostrado na figura 3.15.

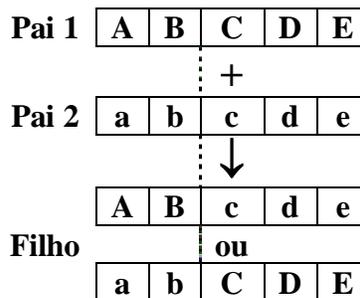


Figura 3.15 - Esquema da recombinação de um ponto

Mutação

Existem vários mecanismos de mutação em estratégias evolutivas. A seguir são descritos os principais deles.

Supondo a inclusão do desvio padrão σ no indivíduo, o novo indivíduo será, em termos gerais, o indivíduo adicionado de uma variável. A partir de um valor inicial, essa variável é obtida da distribuição normal de média zero e desvio padrão σ , como visto na equação 3.16 [31].

$$x' = x + N(0, \sigma). \quad (3.16)$$

A mutação do desvio padrão varia de acordo com o caso. Se cada indivíduo tiver um único desvio padrão, ele muta como se vê na equação 3.17.2. O novo indivíduo é fruto da adição ao indivíduo anterior do produto entre o novo desvio padrão e um fator dependente da distribuição normal, como mostrado na equação 3.17.1 [31].

$$\begin{aligned} \text{Indivíduo} &= [x_1, \dots, x_n; \sigma], \\ \begin{cases} x' = x + \sigma' \cdot N(0,1) & (1) \\ \sigma' = \sigma \cdot e^{\tau \cdot N(0,1)} & (2) \end{cases} & \quad (3.17) \end{aligned}$$

Se cada indivíduo tiver um desvio padrão para cada gene [31], o desvio padrão mutará como na equação 3.18.2 e o novo indivíduo seguirá a equação 3.18.1.

$$\begin{aligned} \text{Indivíduo} &= [x_1, \dots, x_n, \sigma_1, \dots, \sigma_n], \\ \begin{cases} x'_i = x_i + \sigma'_i \cdot N_i(0,1) & (1), \\ \sigma'_i = \sigma_i \cdot e^{\tau \cdot N(0,1) + \tau \cdot N_i(0,1)} & (2), \end{cases} & \quad (3.18) \end{aligned}$$

onde $\tau' \propto 1/(2n)^{1/2}$ e $\tau \propto 1/(2n^{1/2})^{1/2}$.

Se os genes que formam o indivíduo estão correlacionados, uma nova variável, α , fará parte do indivíduo. Os desvios padrões e correlações formarão a matriz de covariância, equação 3.19 [31]. A matriz de covariância possui como características ser simétrica e definida positiva. A mutação de indivíduos que possuem desvio padrão e correlações segue a equação 3.20 [31]. Os desvios padrões são mutados segundo a equação 3.20.3 e as correlações seguem a equação 3.20.2. Assim uma nova matriz C é formada, recebendo a denominação de C'. Finalmente, a mutação de um indivíduo é descrita na equação 3.20.1.

$$C \begin{cases} \sigma_i^2 \\ 1/2 \cdot (\sigma_i^2 - \sigma_j^2) \cdot \text{tg}(2\alpha_{ij}), \end{cases}, \quad (3.19)$$

Indivíduo = $[x_1, \dots, x_n, \sigma_1, \dots, \sigma_n, \alpha_1, \dots, \alpha_k]$,

$$\begin{cases} x_i' = x_i + N(0, C') & (1), \\ \alpha_j' = \alpha_j + \beta \cdot N(0, 1) & (2), \\ \sigma_i' = \sigma_i \cdot e^{\tau \cdot N(0, 1) + \tau \cdot N_i(0, 1)} & (3), \end{cases} \quad (3.20)$$

onde

$$k = n \cdot (n-1) / 2,$$

$$\tau' \propto 1/(2n)^{1/2} \text{ e } \tau \propto 1/(2n^{1/2})^{1/2}, \text{ e se } \sigma_i' < \varepsilon_0 \Rightarrow \sigma_i' = \varepsilon_0,$$

$$|\alpha| > \pi \text{ e}$$

$$\beta < 5^\circ.$$

Seleção

A seleção é um parâmetro que procura direcionar o algoritmo para as áreas que sejam promissoras na busca pelo melhor indivíduo através dos indivíduos já existentes. No caso das estratégias evolutivas, a seleção pode incluir os indivíduos da população filhos e a população de pais, $(\mu+\lambda)$ -EE, ou somente utilizar a população que acabou de ser gerada, (μ,λ) -EE. Em ambos os casos μ indivíduos são selecionados e estes são recombinados até gerar λ indivíduos.

Critérios de parada

Os critérios de parada podem ser, por exemplo:

- número de gerações, onde se pré-determina o número de gerações que o algoritmo executará;
- estagnação, a quantidade de gerações para as quais o melhor indivíduo pode se repetir é fixada e se esse número for atingido o algoritmo será interrompido;
- tempo de computação, a quantidade máxima de tempo no qual o algoritmo atuará;
- objetivo alcançado, o algoritmo será interrompido quando algum objetivo pré-estabelecido for alcançado

Algoritmo Genético

Nesse artigo [33] os autores dissertam sobre as dificuldades dos ajustes dos parâmetros em algoritmos evolutivos e destacam que o uso de parâmetros fixos faz com que o processo de busca seja sub-ótimo. O controle de parâmetros auto-adaptativos é o alvo do artigo e em particular a pressão de seleção e o tamanho da população que são incluídos em cada indivíduo, denominados $p_i \in \{p_{\min}, p_{\max}\}$. Esses valores de p são agregados e formam o valor P que será o valor do tamanho da população e o tamanho do torneio. O mecanismo de agregação que forma P tem o valor de:

$$P = \sum_{i=1}^N p_i, \quad (3.21)$$

onde $p_i \in [p_{\min}, p_{\max}]$ e N é o tamanho da população atual.

A forma de mutação desses parâmetros p é guiada pela equação abaixo:

$$p' = (1 + (1-p)/p * e^{-0.22 * N(0,1)})^{-1}. \quad (3.22)$$

Após essas considerações, os autores realizam variados testes com algoritmo genético e concluem que é possível a auto-adaptação eficiente da pressão de seleção e do tamanho da população em um algoritmo evolutivo.

Outro artigo pode ser citado [34], onde o autor, baseado na auto-adaptação utilizada nas estratégias evolutivas, incorpora a taxa de mutação na representação do indivíduo em algoritmo genético.

Após o conhecimento das meta-heurísticas utilizadas no sistema-teste e do ajuste de parâmetros utilizadas em cada uma delas, oito configurações foram elaboradas para as estratégias evolutivas visando à auto-adaptação dos parâmetros de busca. O recozimento simulado adaptativo difuso foi testado com a mesma configuração, mas com dois tipos de vazões afluentes: as determinísticas e as estocásticas. Os resultados obtidos com a aplicação dessa meta-heurísticas serão apresentados, assim como a análise gráfica e a comparação entre as metodologias aplicadas nessa dissertação e na dissertação [1].

Capítulo 4

Sistema-teste e resultados

4.1 - Introdução

Como visto no capítulo 2, o problema de despacho hidrotérmico possui suas dificuldades de resolução devido às várias restrições ao qual ele é submetido e a sua característica não convexa. No capítulo 3, houve a apresentação de meta-heurísticas capazes de lidar com funções de diversas naturezas. A partir disso, esse capítulo aplica estratégias evolutivas e recozimento simulado adaptativo difuso no despacho hidrotérmico em um sistema teste localizado na bacia do rio São Francisco, composto de sete usinas hidrelétricas e seis usinas térmicas, e compara os resultados obtidos com os encontrados na aplicação de outras meta-heurísticas [1].

4.2 - Sistema Teste

O objetivo do despacho hidrotérmico do sistema teste é a realização do planejamento em médio prazo com horizonte de estudo de dois anos, discretizados mensalmente, para o atendimento de uma demanda de 8500 MW-médios e das restrições associadas.

Usinas Hidrelétricas

As sete usinas hidrelétricas que compõem o sistema-teste localizado na bacia do São Francisco são: Três Marias, Sobradinho, Itaparica, Moxotó, Paulo Afonso 1, 2, 3, Paulo Afonso 4 e Xingó. Com exceção de Três Marias cujo agente responsável é a CEMIG, todas as demais usinas pertencem a CHESF. A potência instalada em cada usina encontra-se na figura 4.1 [46].

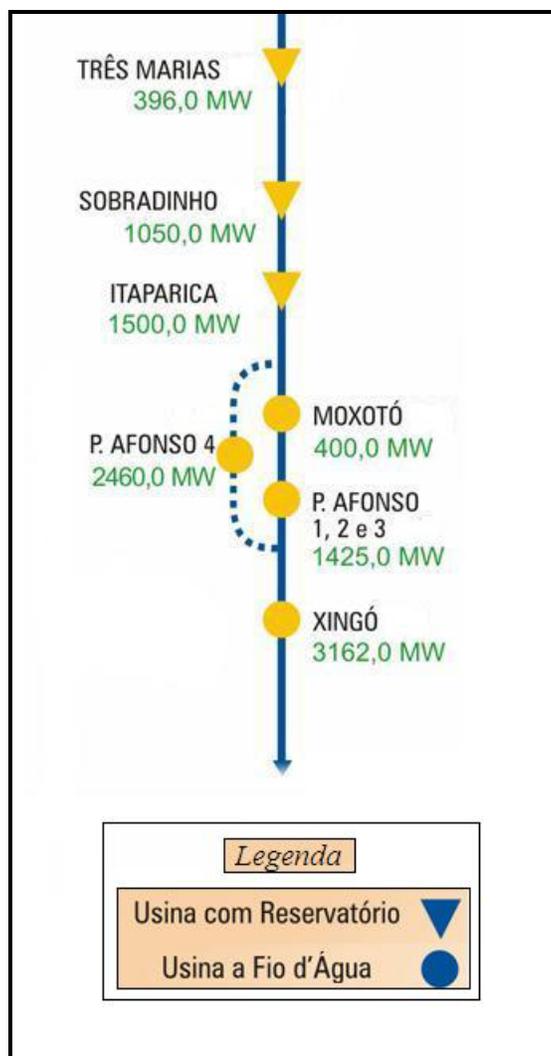


Figura 4.1 - Usinas em estudo na bacia do rio São Francisco.

As usinas do complexo de Paulo Afonso, Moxotó e Xingó são usinas modeladas como fio d'água e o motivo é o pequeno volume útil de seus reservatórios como percebemos na tabela 4.1.

Nas tabelas 4.2, 4.3 e 4.4 seguem os dados técnicos das usinas de reservatório Três Marias, Sobradinho e Itaparica, respectivamente. Nas tabelas 4.5, 4.6, 4.7 e 4.8 encontram-se os dados técnicos das usinas fio d'água Moxotó, Paulo Afonso 1, 2 e 3, Paulo Afonso 4 e Xingó.

Tabela 4.1 - Características das usinas hidrelétricas.

USINA	POTÊNCIA INSTALADA (MW)	VOLUME ÚTIL (hm ³)	VAZÃO INCREMENTAL (m ³ /s)
Três Marias	396	15278	684
Sobradinho	1050	28669	1996
Itaparica	1500	3548	94
Moxotó	400	226	22
Paulo Afonso 1, 2, 3	1425	90	0
Paulo Afonso 4	2460	30	0
Xingó	3162	0	0

Tabela 4.2 - Três Marias.

VOLUME x (hm^3)	MÁXIMO	19.528	NÍVEL DE ARMAZENAMENTO (m)		MÍNIMO	545					
	MÍNIMO	4.250			MÁXIMO	568					
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) $\Phi(x)$											
a_0		a_1		a_2		a_3					
5,3037 x 10 ²		4,3359 x 10 ⁻³		-2,4529 x 10 ⁻⁷		8,8877 x 10 ⁻¹²					
						a_4					
						-1,3347 x 10 ⁻¹⁶					
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) $\theta(u)$											
a_0		a_1		a_2		a_3					
5,10037 x 10 ²		1,92841x 10 ⁻³		-1,74094 x 10 ⁻⁷		1,2127 x 10 ⁻¹¹					
						a_4					
						-3,24195 x 10 ⁻¹⁶					
PRODUTIVIDADE K (MW/m³/s/m)		ENGOLIMENTO MÁXIMO q_{MÁX} (m³/s)		DEFLUÊNCIA MÁXIMA u_{MÁX} (m³/s)		DEFLUÊNCIA MÍNIMA u_{MÍN} (m³/s)					
0,008564		924		1386		500					
VAZÕES INCREMENTAIS y (m³/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
454,29	340,08	274,94	225,49	221,91	302,87	612,07	1100,59	1462,51	1376,24	1131,95	746,35

Tabela 4.3 - Sobradinho.

VOLUME x (hm^3)	MÁXIMO	34.116	NÍVEL DE ARMAZENAMENTO (m)	MÍNIMO	380,5						
	MÍNIMO	5.447		MÁXIMO	392,5						
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) $\Phi(x)$											
a₀	a₁	a₂	a₃	a₄							
$3,741790 \times 10^2$	$1,39669 \times 10^{-3}$	$-5,35159 \times 10^{-8}$	$1,15599 \times 10^{-12}$	$-9,54599 \times 10^{-18}$							
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) $\theta(u)$											
a₀	a₁	a₂	a₃	a₄							
$3,606096 \times 10^2$	$1,24821 \times 10^{-3}$	$-1,278032 \times 10^{-7}$	$9,302374 \times 10^{-12}$	$-2,6311 \times 10^{-16}$							
PRODUTIVIDADE K ($MW/m^3/s/m$)	ENGOLIMENTO MÁXIMO $q_{MÁX}$ (m^3/s)	DEFLUÊNCIA MÁXIMA $u_{MÁX}$ (m^3/s)	DEFLUÊNCIA MÍNIMA $u_{MÍN}$ (m^3/s)								
0,009025	4278	6417	640								
VAZÕES INCREMENTAIS y (m^3/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
1879,17	1251,37	1056,35	926,55	808,61	850,13	1285,47	2323,89	3288,37	3621,67	3731,47	3040,64

Tabela 4.4 - Itaparica.

VOLUME x (hm³)	MÁXIMO	10.782	NÍVEL DE ARMAZENAMENTO (m)				MÍNIMO	299			
	MÍNIMO	7.238					MÁXIMO	304			
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) Φ(x)											
a₀		a₁	a₂	a₃	a₄						
2,75813 x 10 ²		6,76489 x 10 ⁻³	-8,86837 x 10 ⁻⁷	7,06791 x 10 ⁻¹¹	-2,23985 x 10 ⁻¹⁵						
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) θ(u)											
				a₀		2,515 x 10 ²					
PRODUTIVIDADE K (MW/m³/s/m)		ENGOLIMENTO MÁXIMO q_{MÁX} (m³/s)		DEFLUÊNCIA MÁXIMA u_{MÁX} (m³/s)		DEFLUÊNCIA MÍNIMA u_{MÍN} (m³/s)					
0,008927		3306		4959		640					
VAZÕES INCREMENTAIS y (m³/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
188,81	64,35	30,39	35,39	29,92	0	0	0	36,24	122,97	295,12	323,48

Tabela 4.5 - Moxotó.

VOLUME x (hm^3)	MÁXIMO	900	NÍVEL DE ARMAZENAMENTO (m)	MÍNIMO	251,5						
	MÍNIMO	900		MÁXIMO	251,5						
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) $\Phi(x)$			a_0	$2,515 \times 10^2$							
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) $\theta(u)$			a_0	$2,303 \times 10^2$							
PRODUTIVIDADE K ($\text{MW}/\text{m}^3/\text{s}/\text{m}$)	ENGOLIMENTO MÁXIMO $q_{\text{MÁX}}$ (m^3/s)	DEFLUÊNCIA MÁXIMA $u_{\text{MÁX}}$ (m^3/s)	DEFLUÊNCIA MÍNIMA $u_{\text{MÍN}}$ (m^3/s)								
0,009064	2200	3300	640								
VAZÕES INCREMENTAIS y (m^3/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
58,25	22,55	13,61	13,32	12,32	0	0	0	0	20,08	49,19	80,21

Tabela 4.6 - Paulo Afonso 1, 2, 3.

VOLUME x (hm ³)	MÁXIMO	260	NÍVEL DE ARMAZENAMENTO (m)		MÍNIMO	230,30					
	MÍNIMO	260			MÁXIMO	230,30					
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) $\Phi(x)$			a₀		2,303 x 10 ²						
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) $\theta(u)$											
a₀		a₁		a₂		a₃					
1,3412 x 10 ²		3,31878 x 10 ⁻³		-3,09259 x 10 ⁻⁷		2,15278 x 10 ⁻¹¹					
PRODUTIVIDADE K (MW/m³/s/m)		ENGOLIMENTO MÁXIMO q_{MÁX} (m³/s)		DEFLUÊNCIA MÁXIMA u_{MÁX} (m³/s)		DEFLUÊNCIA MÍNIMA u_{MÍN} (m³/s)					
0,0088		2144		3216		640					
VAZÕES INCREMENTAIS y (m³/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
0	0	0	0	0	0	0	0	0	0	0	0

Tabela 4.7 - Paulo Afonso 4.

VOLUME x (hm ³)	MÁXIMO	128	NÍVEL DE ARMAZENAMENTO (m)				MÍNIMO	251,5			
	MÍNIMO	128					MÁXIMO	251,5			
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) Φ(x)			a₀				2,515 x 10 ²				
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) θ(u)											
a₀		a₁		a₂		a₃		a₄			
1,29044 x 10 ⁻²		2,07974 x 10 ⁻³		-5,27068 x 10 ⁻⁸		6,66456 x 10 ⁻¹³		-2,23117 x 10 ⁻¹⁷			
PRODUTIVIDADE K (MW/m³/s/m)		ENGOLIMENTO MÁXIMO q_{MÁX} (m³/s)			DEFLUÊNCIA MÁXIMA u_{MÁX} (m³/s)			DEFLUÊNCIA MÍNIMA u_{MÍN} (m³/s)			
0,009035		2400			3600			640			
VAZÕES INCREMENTAIS y (m³/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
0	0	0	0	0	0	0	0	0	0	0	0

Tabela 4.8 - Xingó.

VOLUME x (hm ³)	MÁXIMO	3944	NÍVEL DE ARMAZENAMENTO (m)				MÍNIMO	138			
	MÍNIMO	3944					MÁXIMO	138			
COEFICIENTES DO POLINÔMIO COTA DE MONTANTE =F(VOLUME) $\Phi(x)$				a₀		1,38 x 10 ²					
COEFICIENTES DO POLINÔMIO COTA DE JUSANTE =F(DEFLUÊNCIA) $\theta(u)$											
a₀		a₁		a₂		a₃		a₄			
1,3721 x 10 ²		2,47288 x 10 ⁻³		-3,22059 x 10 ⁻⁷		2,28884 x 10 ⁻¹¹		-5,81037 x 10 ⁻¹⁷			
PRODUTIVIDADE K (MW/m³/s/m)		ENGOLIMENTO MÁXIMO q_{MÁX} (m³/s)			DEFLUÊNCIA MÁXIMA u_{MÁX} (m³/s)			DEFLUÊNCIA MÍNIMA u_{MÍN} (m³/s)			
0,009025		2796			4194			650			
VAZÕES INCREMENTAIS y (m³/s)											
Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	abr
0	0	0	0	0	0	0	0	0	0	0	0

Usinas Térmicas

As seis usinas térmicas que compõem o sistema teste são: Termopernambuco, Termofortaleza, Fafen, Termoceará, Termobahia e Camaçari. A capacidade de geração e os respectivos custos estão na tabela 4.9. [1]

Tabela 4.9 - Características das usinas térmicas.

	USINA	POTENCIA INSTALADA (MW)	CUSTO VARIAVEL UNITÁRIO (R\$/MWh)
1	Termopernambuco	638	60,00
2	Termofortaleza	347	66,74
3	Fafen	151	71,29
4	Termo Ceará	220	82,72
5	Termobahia	186	87,12
6	Camaçari	347	130,50

Como visto no capítulo 2, as usinas com menores custos incrementais são despachadas antes das mais custosas, sendo assim, a tabela 4.9 apresenta a ordem de despacho das usinas. A tabela 4.10, apresenta o despacho térmico otimizado [1], cuja função custo horário é representada por funções lineares na geração térmica total. Na figura 4.2, encontra-se os passos que ilustram o modelo adotado para simular a operação em cascata do sistema-teste [1].

Tabela 4.10 - Despacho térmico otimizado.

FAIXA DE OPERAÇÃO (MW)	USINAS DESPACHADAS	CUSTO HORÁRIO (R\$/h)
$0 \leq G_t \leq 638$	1	$60 G_t$
$638 < G_t \leq 985$	1 e 2	$66,74 G_t - 4291,12$
$985 < G_t \leq 1136$	1, 2 e 3	$71,29 G_t - 8781,87$
$1136 < G_t \leq 1356$	1, 2, 3 e 4	$82,72 G_t - 21766,35$
$1356 < G_t \leq 1542$	1, 2, 3, 4 e 5	$87,12 G_t - 27732,75$
$1542 < G_t \leq 1889$	1, 2, 3, 4, 5 e 6	$130,5 G_t - 94624,71$
$G_t > 1889$	Todas, com corte de carga	$855,31 G_t - 1463790,80$

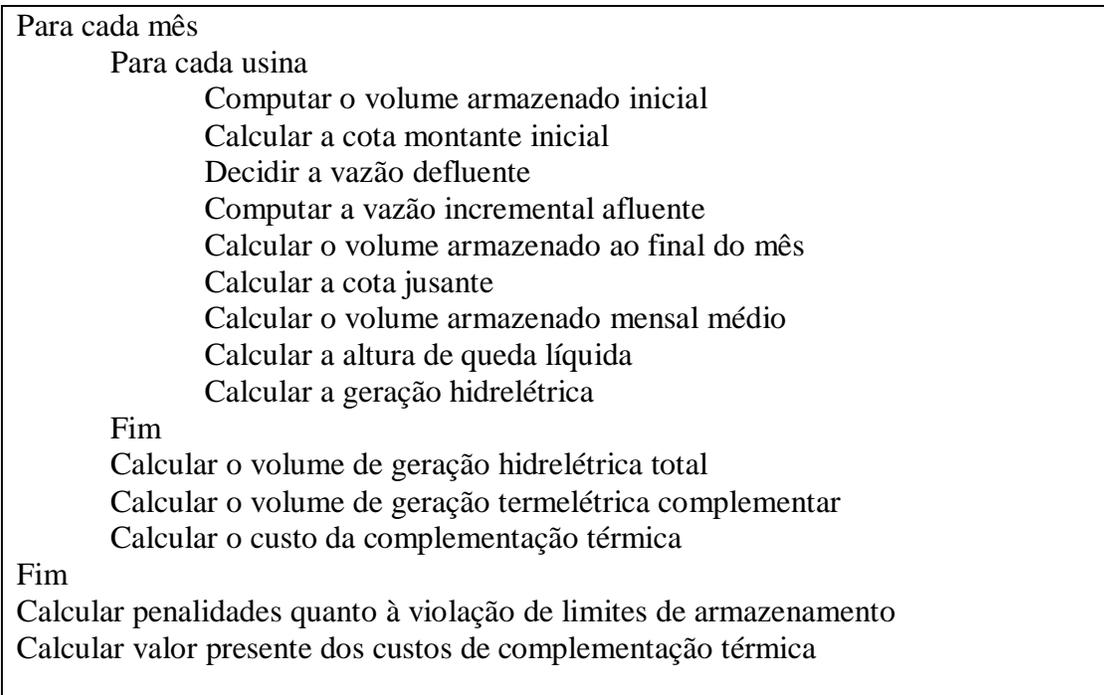


Figura 4. 2 - Simulador de Operação da Cascata das usinas do sistema-teste.

O simulador de operação da cascata das usinas do sistema-teste é chamado a cada iteração onde a meta-heurística fornece como entrada a vazão defluente para as três usinas de reservatório e o simulador, calcula armazenamentos dos reservatórios, vazões defluentes de todas as usinas no sistema-teste, a geração hidrelétrica, a geração térmica entre outros cálculos. O simulador de operação tem como saída o custo associado a cada vazão defluente fornecida.

O tipo de penalização utilizada é a técnica de penalidades exteriores⁴, onde se adicionou uma parcela à função objetivo com a finalidade de penalizar soluções que violam os limites estabelecidos, de mínimo ou máximo, das grandezas ‘vazão defluente’ e ‘armazenamento final’ no reservatório das usinas. Sendo assim, a função objetivo pode ser reescrita como visto na equação 4.1:

⁴ O método de penalidades exteriores consiste em transformar um problema de programação não-linear com restrições de desigualdades em vários problemas sem restrições, via adição de parcelas na função objetivo. Essas parcelas adicionadas têm como finalidade penalizar as soluções que não satisfazem as restrições impostas pelo problema a ser tratado [47].

$$\min \sum_{t=1}^T [\lambda_t \cdot \sum_{j=1}^J \psi_j(g_{j,t}) + \alpha w_1 (x_{i,t} - x_{i,t}^{máx,mín})^2 + \beta w_2 (u_{i,t} - u_{i,t}^{máx,mín})^2] \quad (4.1)$$

onde

$\alpha = 1$, se $x_{i,t} < x_{i,t}^{mín}$ ou $x_{i,t} > x_{i,t}^{máx}$;

$\alpha = 0$, do contrário.

$\beta = 1$, se $u_{i,t} < u_{i,t}^{mín}$ ou $u_{i,t} > u_{i,t}^{máx}$;

$\beta = 0$, do contrário.

w_1 e w_2 ponderam o custo da penalidade e no nosso caso tem valor de $5 \cdot 10^8$.

λ_t fator de desconto é de 1% ao mês.

Com essa forma de penalização, as soluções não-viáveis são aceitas pela meta-heurística, pois o custo associado a essas soluções são elevados proporcionalmente à violação correspondente. Posto isso, pode-se descrever a função adequabilidade utilizada no problema:

Cálculo da geração hidrelétrica, térmica e do custo da complementação térmica

Para cada mês

Para cada usina

Calcular a geração hidrelétrica das usinas de reservatório e fio d'água

Fim

Calcular o volume de geração hidrelétrica total

Calcular o volume de geração termelétrica complementar

Geração Térmica = Demanda - Geração hidrelétrica total

Se Geração Térmica ≥ 0

Calcular o custo da complementação térmica de acordo com o nível de geração (Tabela 4.10)

Fim

Cálculo de Penalidades

Para cada mês

Para cada usina de reservatório (Três Marias, Sobradinho e Itaparica)

Se Armazenamento Final < Armazenamento Mínimo

Custo=Custo+5e8*(armazenamento final –armazenamento mínimo)²;

Se Armazenamento Final > Armazenamento Máximo

Custo=Custo+5e8*(armazenamento final –armazenamento máximo)²;

Se Vazão Defluente < Turbinamento Mínimo
Custo=Custo+5e8*(vazão defluente – turbinamento mínimo)²;

Cálculo do valor presente dos custos de complementação térmica

Se Geração Hidrelétrica ≤ 8.500 (demanda)

Custo Total = Fator de Desconto*(Custo da complementação térmica + Custo das penalidades)

Senão

Custo Total = Fator de Desconto*(Penalidade de 1e8 + Custo das penalidades)

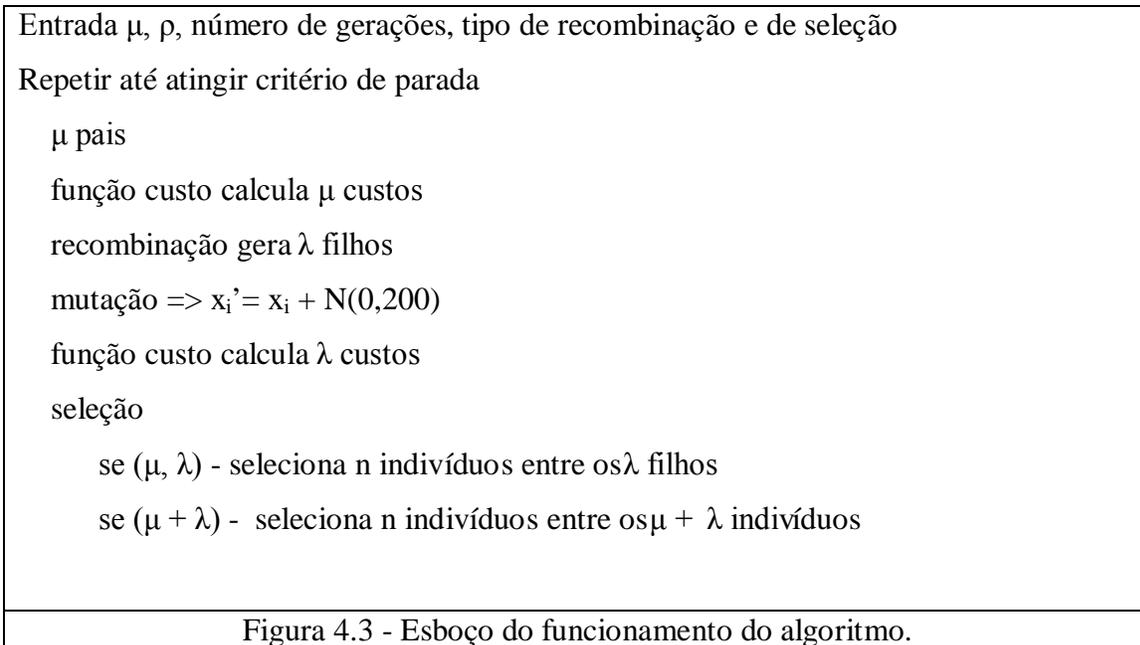
Para um melhor entendimento da função adequabilidade, o código encontra-se no anexo. Com todas as informações necessárias descritas nessa seção, aplicamos as meta-heurísticas estratégias evolutivas e recozimento simulado adaptativo difuso no sistema-teste. Suas configurações e resultados encontram-se nas seções que se seguem.

4.3 - Aplicação das estratégias evolutivas no sistema teste

A aplicação das estratégias evolutivas no sistema estudado teve início com a definição das variáveis de entrada e saída. Os dados de entrada são: o número de pais μ ; número de pais que geram um filho ρ ; tipo de recombinação, se discreta ou intermediária; de seleção, $(\mu+\lambda)$ ou (μ, λ) ; e o número de gerações. Os dados de saída são: menor custo, o indivíduo que gerou o menor custo e a geração a qual pertence esse indivíduo.

Para realização de testes preliminares, um algoritmo base foi desenvolvido e aos poucos aperfeiçoado na busca da melhor configuração para aplicação no sistema-teste da figura 4.1. O indivíduo variou de tamanho conforme os testes realizados, sendo o seu tamanho mínimo com 72 genes, relacionados às 24 vazões das três usinas hidrelétricas de reservatório. Internamente, o algoritmo gera aleatoriamente μ indivíduos e calcula o custo de cada um através do simulador de operação. Em seguida, através da recombinação, a população de pais, μ , é elevada a sete vezes devido à pressão de seleção sugerida por [31]. A recombinação é feita pela combinação de pais que geram um filho, esse processo é repetido até a formação da população de filhos, λ . Depois de recombinação, a população é mutada, por meio de uma perturbação gaussiana de média zero e desvio padrão 200 e

avaliada pela função custo. Em seguida, a seleção usada é a torneio [1]. A população que participa da seleção é formada, no caso de $(\mu+\lambda)$, pela população de pais e filhos gerando uma população temporária para selecionar n indivíduos. No caso de (μ, λ) , somente a população de filhos é utilizada para a seleção de n indivíduos. O critério de parada implementado é o número de gerações. Todas essas informações estão na figura 4.3.



Após a realização de alguns testes, algumas decisões foram tomadas: o valor de ρ foi fixado igual a dois, a recombinação discreta foi o tipo de recombinação escolhida e a seleção (μ, λ) foi considerada a mais adequada para o problema a ser tratado.

Sobre os resultados obtidos com a recombinação intermediária, eles ficaram bem aquém das expectativas. O motivo da escolha do valor de ρ igual a dois e pelo qual se optou pela seleção (μ, λ) é que os valores de ρ acima de dois e a seleção $(\mu + \lambda)$ apesar de gerarem resultados próximos ao esperado, elevaram o tempo computacional.

A seguir, com o objetivo de testar as estratégias evolutivas em coordenação hidrotérmica, oito casos são simulados, cujo foco principal é a auto-adaptação de alguns parâmetros. Esses parâmetros são: o tamanho do torneio, o tamanho da população e o valor do desvio padrão. Como visto no capítulo 3, há várias formas de classificação do controle

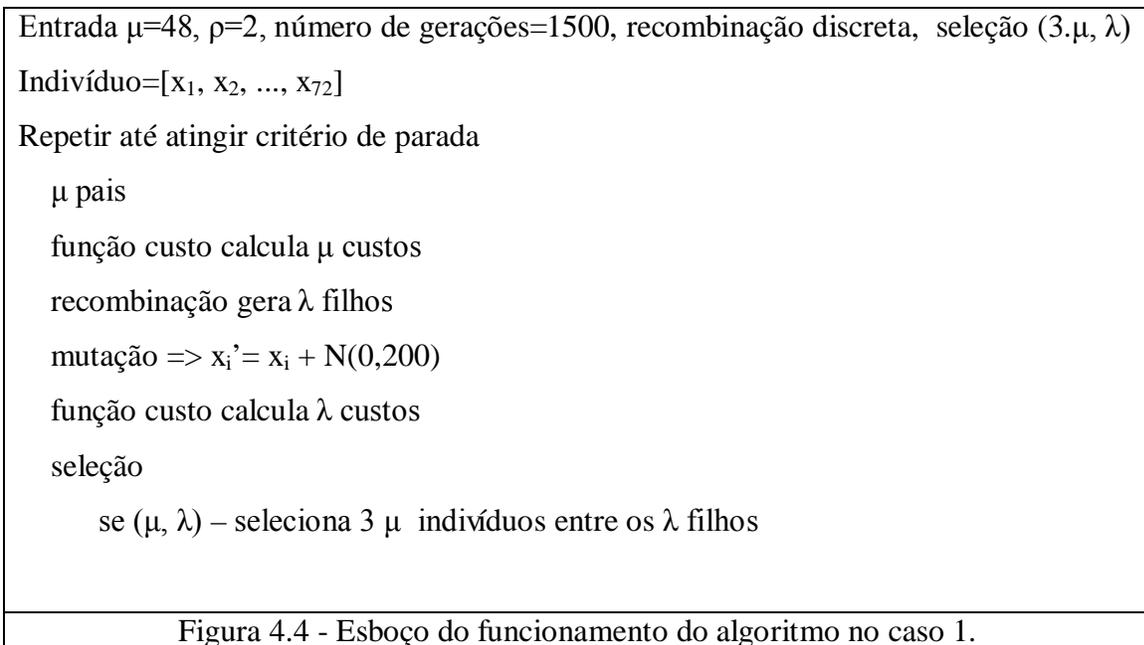
de parâmetros, fixos e controle de parâmetros, que por sua vez se subdivide em determinístico, adaptativo e auto-adaptativo. Sendo assim, cada caso é intitulado com base nessa classificação.

O caso 1 possui tamanho de população fixo, assim como o tamanho do torneio e o desvio padrão é determinístico. No caso 2, o tamanho da população segue fixo, bem como o desvio padrão determinístico, entretanto o tamanho do torneio é inserido como gene no indivíduo, ou seja, é auto-adaptativo. O caso 3 mantém a população fixa e a seleção torneio auto-adaptativo, mas há a inclusão dos valores de desvio padrão no indivíduo como um gene. No caso 4, há mudança do tipo de seleção torneio para a seleção aleatória. O caso 5 se diferencia do caso 4, pelo fato de não haver recombinação. No caso 6, o tamanho da população está inserido no gene, do mesmo modo que estão o tamanho do torneio, e os desvios padrões. O caso 7 possui as mesmas características do caso 6, com a inclusão das correlações no indivíduo. Finalmente o caso 8, que se difere do caso 6 no tipo de vazão afluente utilizada que é a estocástica, enquanto em todos os casos anteriormente citados são vazões afluentes determinísticas, as MLT's. Todos esses casos serão melhores descritos a seguir.

Caso 1 - Tamanho da população fixo, tamanho do torneio fixo e desvio padrão determinístico

Na primeira versão do algoritmo usando o sistema-teste, o indivíduo possuía 72 genes. Como visto, os genes são formados pelas vazões mensais das três usinas de acumulação durante os dois anos de previsão. As probabilidades de recombinação testadas foram altas: 100%, 95%, 90% e 85% e a probabilidade de mutação foi de 1%. O tipo de seleção era torneio 4 (onde dentro da população de filhos quatro são selecionados aleatoriamente e o melhor entre eles é selecionado para compor a população de pais da próxima geração). Esse processo é repetido até que seja atingido o tamanho da população. A taxa de mutação e o tamanho do torneio foram escolhidos devido à utilização na dissertação [1].

A mutação era dada pela adição de uma perturbação com distribuição gaussiana de média zero e desvio padrão 200 ao indivíduo original. O valor dado ao desvio padrão foi escolhido por gerar uma perturbação significativa nos genes que fossem mutados. A pressão de seleção era de 3μ sendo dois desses valores escolhidos por elitismo, ou seja, os dois melhores indivíduos estarão sempre na próxima geração. A princípio vale 48 e por isso a seleção de 3μ como o número de indivíduos selecionados para a próxima geração, ou seja, 144 indivíduos, número de indivíduos usados em [1]. Essa primeira versão do algoritmo teve bastante influência do trabalho [1], pois foi à maneira encontrada para validação ou não do algoritmo. Os resultados encontram-se na tabela 4.11 na seção 4.4.



Caso 2 - Tamanho da população fixo, seleção torneio auto-adaptativo e desvio padrão determinístico

O primeiro parâmetro a ser incluso foi o tamanho do torneio, ou seja, a quantidade de filhos k , que seriam escolhidos aleatoriamente para que fosse selecionado o melhor indivíduo entre os k , repetindo n vezes o processo até atingir o número de indivíduos, n , para a próxima geração. Com isso, o indivíduo passou a ter 73 genes, figura 4.4. Nesse caso o tamanho do torneio variava entre 0% e 10% da população, valor adotado em [33] e limitando o torneio mínimo a torneio 2, assim o tamanho do torneio passou a ser auto-

adaptativo. A taxa de mutação se mantinha em 1% e o modo de mutar o indivíduo era dado pela gaussiana de média 0 e desvio padrão 200, e a mutação do torneio dada pela equação (3.22), como sugerido em [33]. A pressão de seleção não foi modificada. As taxas de recombinação testadas foram as três melhores apresentadas no caso 1.

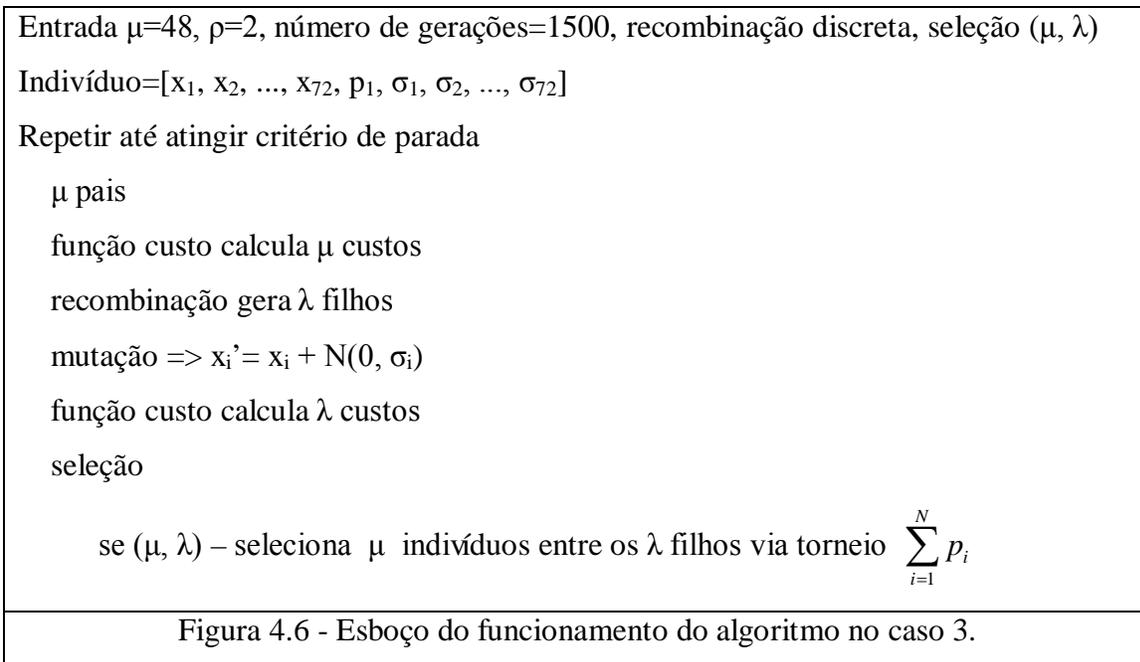
Entrada $\mu=48$, $\rho=2$, número de gerações=1500, recombinação discreta, seleção $(3.\mu, \lambda)$
 Indivíduo= $[x_1, x_2, \dots, x_{72}, p_1]$
 Repetir até atingir critério de parada
 μ pais
 função custo calcula μ custos
 recombinação gera λ filhos
 mutação $\Rightarrow x_i' = x_i + N(0,200)$
 função custo calcula λ custos
 tamanho do torneio $\Rightarrow T = \sum_{i=1}^N p_i$, onde N= tamanho da população
 seleção
 se (μ, λ) – seleciona 3 μ indivíduos entre os λ filhos via torneio T ,

Figura 4.5 - Esboço do funcionamento do algoritmo no caso 2.

Caso 3 - Tamanho da população fixo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo

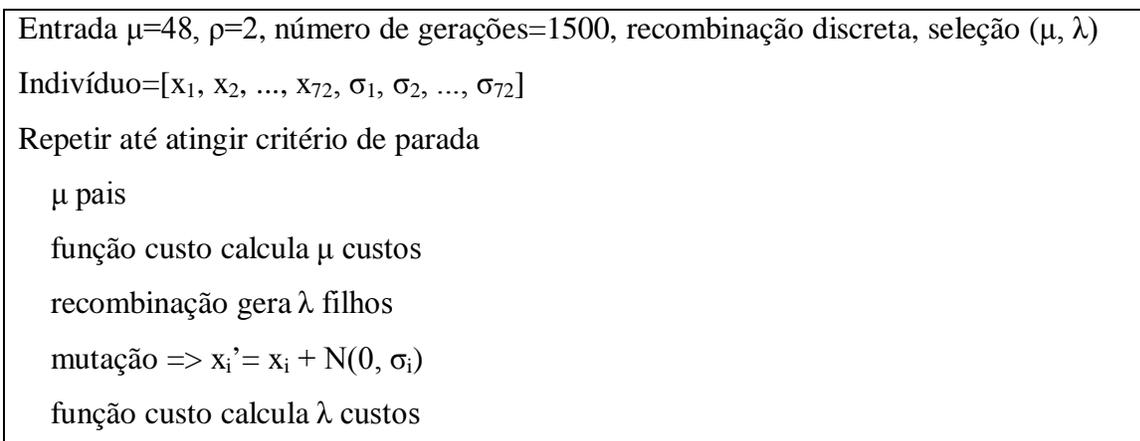
Nessa etapa, o torneio variou de 2 a 10% da população com torneio mínimo de 4. Os desvios padrões passaram a fazer parte do indivíduo, sendo um desvio padrão para cada vazão. Dessa forma, o desvio padrão passou a ser auto-adaptativo, pois passou a sofrer a ação da recombinação e da mutação do indivíduo. Sendo assim, o indivíduo possui o tamanho de 145 genes. A mutação segue a equação 3.17 e o valor inicial desvio padrão era dado por gaussiana de média zero e desvio padrão de 5% do valor da vazão defluente inicial correspondente. O valor mínimo absoluto do desvio padrão é de 1% do valor da vazão, para que a mutação resultasse em uma mudança significativa no indivíduo. Os testes

foram realizados com a seleção torneio auto-adaptativo, figura 4.6. Os resultados correspondentes com taxa de recombinação de 100% encontram-se na tabela 4.13.



Caso 4 - Tamanho da população fixo, seleção aleatória e desvio padrão auto-adaptativo

Nesse caso, o funcionamento do algoritmo é bem parecido com o do caso 3, com modificação do tipo de seleção, de torneio para seleção aleatória de μ dentre os λ existentes na população após a mutação, como visto figura 4.7. Os resultados encontram-se na tabela 4.14.



seleção $se(\mu, \lambda)$ – seleciona aleatoriamente μ indivíduos entre os λ filhos
Figura 4.7 - Esboço do funcionamento do algoritmo no caso 4.

Caso 5 - Tamanho da população fixo, seleção aleatória e desvio padrão auto-adaptativo

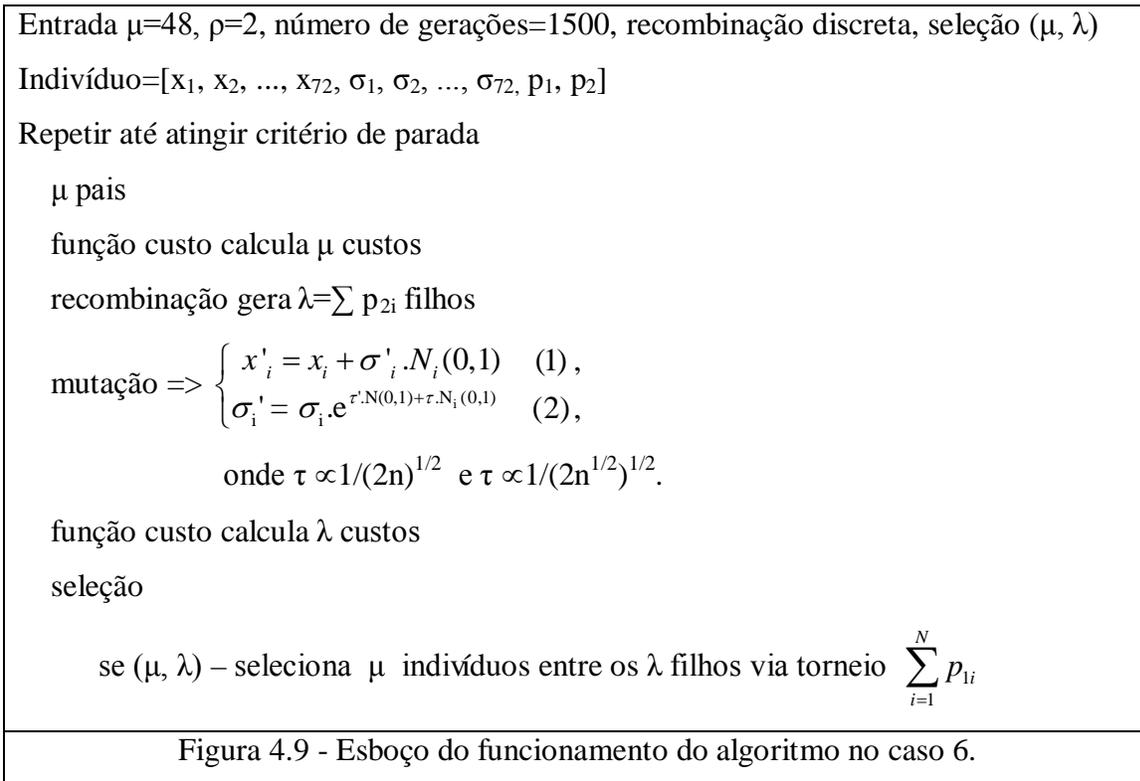
Uma versão mais próxima da origem das estratégias evolutivas foi testada, onde não há recombinação, todos os indivíduos mutam. A seleção dos indivíduos acontece pela escolha aleatória de μ indivíduos dentre os λ indivíduos, figura 4.8. A mutação é dada pela equação 3.17. Os resultados encontram-se na tabela 4.15.

Entrada $\mu=48$, $\rho=2$, número de gerações=1500, recombinação discreta, seleção (μ, λ) Indivíduo= $[x_1, x_2, \dots, x_{72}, \sigma_1, \sigma_2, \dots, \sigma_{72}]$ Repetir até atingir critério de parada μ pais função custo calcula μ custos escolha aleatória de λ indivíduos mutação $\Rightarrow x_i' = x_i + N(0, \sigma_i)$ função custo calcula λ custos seleção $se(\mu, \lambda)$ – seleciona aleatoriamente μ indivíduos entre os λ filhos
Figura 4.8 - Esboço do funcionamento do algoritmo no caso 5.

Caso 6 - Tamanho da população auto-adaptativo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo

Após todos os testes citados, o tamanho da população foi inserido no indivíduo. Desta forma, cada indivíduo contribuiu com um valor para o tamanho da próxima população, ou seja, o número de indivíduos da população não é mais fixo. Cada indivíduo ‘sugere’ valores entre 0,5 e 2, através de uma distribuição uniforme de números aleatórios, o que significa que a população pode ter sua população mínima de metade da população

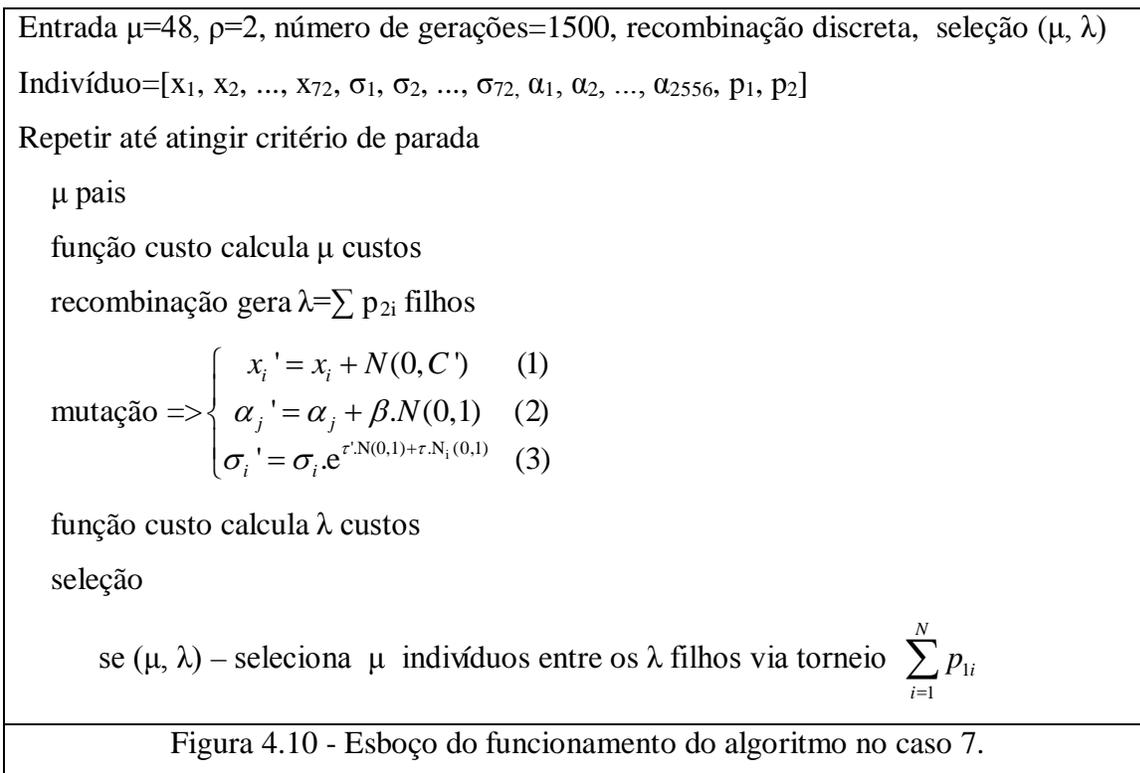
anterior até dobrar de tamanho em relação à população anterior. A variação de tamanho da população possui um limite mínimo de indivíduos e um valor máximo de sete vezes, pois ao não impor limites ao tamanho da população houve problemas com o crescimento populacional explosivo devido à perda de diversidade que se dá no decorrer das gerações. Com isso, o tempo de execução fica demasiadamente alto, inviabilizando a simulação. O torneio voltou a ser o modo de seleção, bem como a manutenção dos dois melhores indivíduos na próxima geração. O modo de mutação mudou e passou a seguir a equação 3.18. Nesse algoritmo todos os indivíduos mutam, figura 4.9. A inclusão do tamanho da população elevou o tempo computacional, que chegou a atingir doze horas⁵ de simulação, e os resultados são encontrados na tabela 4.16.



⁵Computador utilizado: Intel Core 2 Duo, E6550, 2,33Ghz, 2Gb de RAM

Caso 7 - Tamanho da população auto-adaptativo, seleção auto-adaptativo e desvio padrão auto-adaptativo e covariância adaptativa

Esse caso consistiu em dar uma correlação entre as vazões, inserindo assim as covariâncias à mutação correspondente às equações 3.19 e 3.20, figura 4.10. Dessa forma, há a formação da matriz de correlação, que é formada pelos desvios padrões e as covariâncias. A seleção prossegue torneio e a taxa de recombinação de 100%.



Caso 8 - Tamanho da população auto-adaptativo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo, múltiplos cenários de vazões afluentes

Todos os casos anteriores apresentavam uma vazão incremental determinística, ou seja, para o cálculo das vazões eram utilizadas previsões de afluências fixas durante o horizonte de dois anos, as MLT's (médias de longo termo anual).

Neste caso, a configuração é a mesma do caso 6, com exceção das vazões afluentes que são estocásticas, utilizando assim todas as afluições existentes entre os anos 1931 e 2005, totalizando 74 biênios (exemplo: 1931-1932, 1932-1933 e etc). O custo total é calculado pela média de todos os custos desses 74 biênios. A configuração do caso 6 foi escolhida por ser a mais auto-adaptativa dentre as testadas.

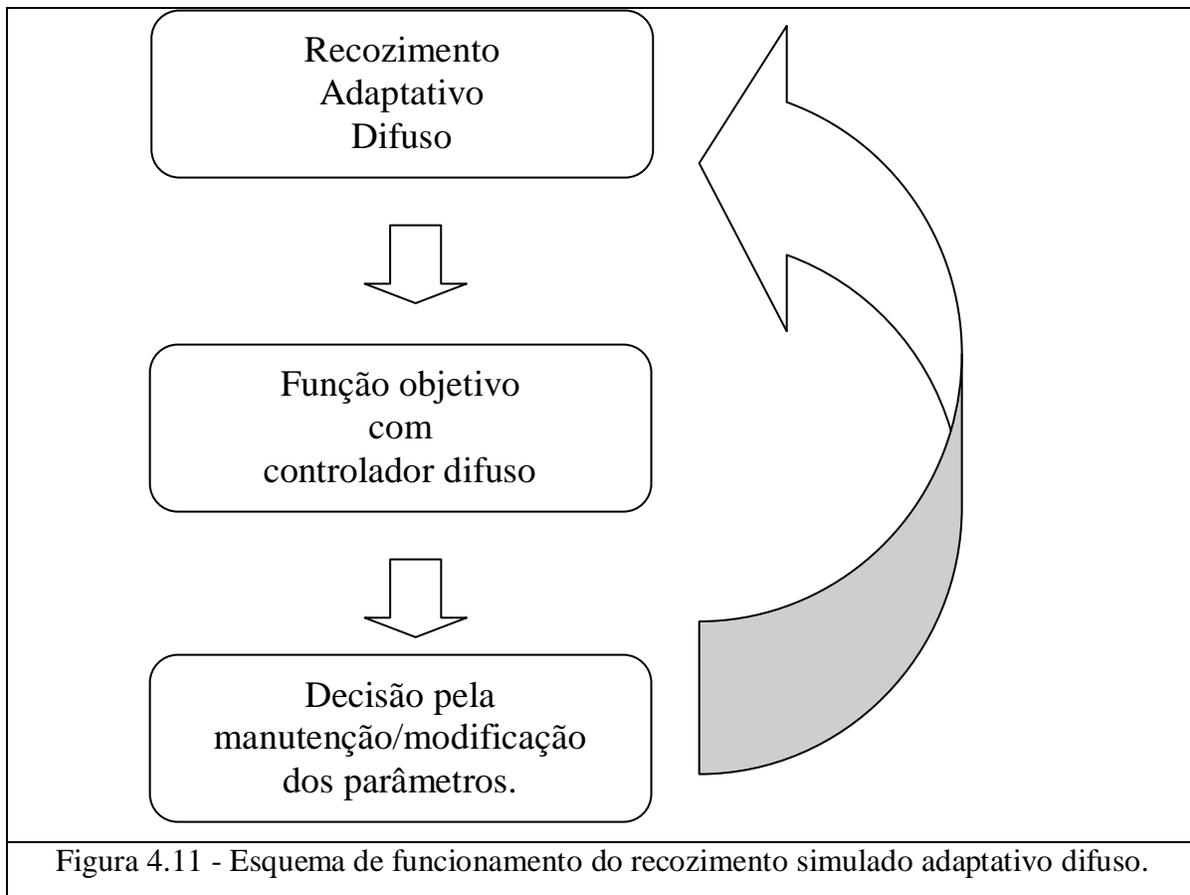
O teste foi realizado utilizando a configuração apresentada na figura 4.9 para a versão determinística. Os custos se mostraram mais elevados do que os encontrados na versão determinística, devido à grande quantidade de restrições envolvidas nos diversos cenários a serem atendidos.

4.4 - Aplicação do recozimento simulado adaptativo

difuso no sistema teste

Para uma melhor avaliação dos resultados obtidos na utilização das estratégias evolutivas para o problema de coordenação hidrotérmica, a meta-heurística recozimento simulado adaptativo difuso [19] também foi aplicada no sistema-teste, tanto para o caso de vazões determinísticas como para as afluições em vários cenários. O funcionamento do algoritmo encontra-se na figura 4.11.

Os tempos computacionais médios até a convergência foram de 5 minutos para o cenário determinístico e de 60 minutos para o cenário estocástico. A linguagem de programação utilizada foi C++ e o computador Intel Core 2 Duo, 1 Ghz. Os resultados estão na seção 4.6 nas tabelas 4.18 e 4.19.



4.5 - Resultados

4.5.1 - Testes com estratégias evolutivas

Caso 1 - Tamanho da população fixo, tamanho do torneio fixo e desvio padrão determinístico

Na tabela 4.11 encontram-se os custos associados à coordenação hidrotérmica obtidos com a variação da taxa de recombinação. Os valores encontrados estão na mesma ordem de grandeza dos valores encontrados em [1] para algoritmo genético com seleção torneio 4 e cruzamento uniforme, que possui média de 2.0266×10^8 e valor mínimo de 1.7118×10^8 . Todos os valores encontrados nas tabelas que seguem estão representando custos em reais (R\$) e dentro das tabelas os valores em destaque (em negrito) são os menores custos encontrados.

Tabela 4.11 - Testes realizados com torneio 4.

Taxa de recom- binação Simulações	100 %	95 %	90 %	85 %
1	1.6266 x 10 ⁸	1.5088 x 10 ⁸	2.3584 x 10 ⁸	2.2725 x 10 ⁸
2	1.6540 x 10 ⁸	1.4204 x 10 ⁸	1.6848 x 10 ⁸	2.3044 x 10 ⁸
3	2.5338 x 10 ⁸	2.2684 x 10 ⁸	1.6504 x 10 ⁸	2.3332 x 10 ⁸
4	1.7034 x 10 ⁸	2.4492 x 10 ⁸	1.6753 x 10 ⁸	2.5798 x 10 ⁸
5	2.1158 x 10 ⁸	1.4561 x 10 ⁸	1.5663 x 10⁸	1.4361 x 10 ⁸
6	1.3477 x 10⁸	2.3229 x 10 ⁸	2.3161 x 10 ⁸	2.2583 x 10 ⁸
7	2.4791 x 10 ⁸	1.6195 x 10 ⁸	2.1535 x 10 ⁸	2.7050 x 10 ⁸
8	2.4169 x 10 ⁸	1.5437 x 10 ⁸	2.3407 x 10 ⁸	1.4112 x 10 ⁸
9	2.3528 x 10 ⁸	1.5447 x 10 ⁸	2.6446 x 10 ⁸	1.4639 x 10 ⁸
10	2.2574 x 10 ⁸	1.5383 x 10 ⁸	1.5833 x 10 ⁸	2.3250 x 10 ⁸
11	2.2900 x 10 ⁸	2.5267 x 10 ⁸	2.4486 x 10 ⁸	2.4751 x 10 ⁸
12	2.1941 x 10 ⁸	1.6216 x 10 ⁸	2.6031 x 10 ⁸	3.9782 x 10 ⁸
13	2.6134 x 10 ⁸	2.5800 x 10 ⁸	2.3001 x 10 ⁸	1.4509 x 10 ⁸
14	2.3354 x 10 ⁸	1.4943 x 10 ⁸	2.1725 x 10 ⁸	2.2328 x 10 ⁸
15	2.1988 x 10 ⁸	2.4421 x 10 ⁸	1.7475 x 10 ⁸	2.2213 x 10 ⁸
16	1.5345 x 10 ⁸	1.4880 x 10 ⁸	2.2805 x 10 ⁸	2.2187 x 10 ⁸
17	1.8340 x 10 ⁸	2.2777 x 10 ⁸	1.9225 x 10 ⁸	2.2269 x 10 ⁸
18	1.5264 x 10 ⁸	2.2419 x 10 ⁸	2.3761 x 10 ⁸	2.4081 x 10 ⁸
19	1.7295 x 10 ⁸	2.3203 x 10 ⁸	2.4378 x 10 ⁸	2.4862 x 10 ⁸
20	1.5590 x 10 ⁸	1.5115 x 10 ⁸	2.2917 x 10 ⁸	2.3856 x 10 ⁸
21	2.5847 x 10 ⁸	1.5707 x 10 ⁸	2.5037 x 10 ⁸	1.6565 x 10 ⁸
22	2.3320 x 10 ⁸	2.5010 x 10 ⁸	2.5457 x 10 ⁸	1.6951 x 10 ⁸
23	1.4643 x 10 ⁸	2.2959 x 10 ⁸	1.6742 x 10 ⁸	2.2667 x 10 ⁸
24	1.5953 x 10 ⁸	1.5885 x 10 ⁸	2.2883 x 10 ⁸	1.5072 x 10 ⁸
25	2.3448 x 10 ⁸	1.4153 x 10⁸	2.3815 x 10 ⁸	2.2533 x 10 ⁸
26	2.0870 x 10 ⁸	2.4156 x 10 ⁸	1.6852 x 10 ⁸	2.2989 x 10 ⁸
27	2.3009 x 10 ⁸	1.4692 x 10 ⁸	2.4597 x 10 ⁸	2.4235 x 10 ⁸

28	1.4802×10^8	1.7514×10^8	2.2443×10^8	2.2045×10^8
29	2.3456×10^8	2.5340×10^8	1.7607×10^8	2.5621×10^8
30	2.2459×10^8	2.7020×10^8	2.4042×10^8	1.5486×10^8
média	$2,0361 \times 10^8$	$1,9473 \times 10^8$	$2,1501 \times 10^8$	$2,1863 \times 10^8$
Desvio padrão	3.9082×10^7	4.5522×10^7	3.4280×10^7	5.1016×10^7
Menor custo	1.3477×10^8	1.4153×10^8	1.5663×10^8	1.4112×10^8

Caso 2 - Tamanho da população fixo, seleção torneio auto-adaptativo e desvio padrão determinístico

A tabela 4.12, mostra os resultados obtidos com o algoritmo da figura 4.4, o qual inclui o torneio no próprio indivíduo. Os testes demonstram que a ordem de grandeza dos custos aumentou neste caso. Analisando os resultados armazenados, a maioria dos custos mais elevados estão relacionados a uma estagnação do tamanho de torneio em seu valor mínimo (nesse caso torneio 2) nas primeiras gerações.

Tabela 4.12 - Testes realizados no caso 2.

Taxa de recom- binação Simulações	100 %	95 %	90 %
1	4.6351×10^8	5.0812×10^{13}	5.5511×10^{13}
2	8.5286×10^8	1.3407×10^9	1.1273×10^9
3	5.0674×10^8	3.3969×10^8	2.6054×10^8
4	2.5113×10^9	3.8298×10^8	3.6768×10^8
5	2.6592×10^8	7.0234×10^8	2.5364×10^8
6	3.7880×10^8	2.4306×10^8	4.6998×10^9
7	3.6004×10^8	6.5098×10^8	9.5951×10^{10}
8	2.7447×10^8	4.6414×10^8	4.9580×10^8
9	2.9133×10^8	7.7311×10^{12}	4.026×10^9
10	$3,0347 \times 10^8$	2.8667×10^8	4.310×10^8
11	1.2658×10^{13}	3.1159×10^8	4.3284×10^9

12	2.7447×10^8	1.1010×10^9	9.2252×10^{12}
13	3.0387×10^8	4.2603×10^{10}	1.3770×10^9
14	7.3920×10^{11}	2.8351×10^8	9.1575×10^8
15	3.3384×10^8	3.3036×10^8	4.0857×10^8
16	8.1013×10^8	1.8164×10^9	3.0301×10^8
17	5.4105×10^9	6.0725×10^9	2.2789×10^8
18	3.7114×10^9	3.8953×10^8	2.3475×10^9
19	2.4444×10^8	8.8694×10^9	9.5717×10^{11}
20	3.2634×10^8	3.3337×10^8	5.1225×10^8
21	3.1461×10^9	3.7530×10^8	1.1760×10^9
22	7.2043×10^8	5.6578×10^8	1.6100×10^9
23	1.5048×10^{13}	5.6962×10^9	2.6701×10^8
24	2.8386×10^8	3.8375×10^8	2.5540×10^9
25	9.5233×10^8	3.8961×10^8	3.1239×10^8
26	1.0656×10^9	1.6692×10^8	2.0095×10^9
27	5.0240×10^{12}	4.6460×10^8	2.3230×10^9
28	1.0750×10^{13}	1.6510×10^{13}	9.5481×10^8
29	3.7126×10^8	3.7113×10^8	3.2563×10^8
30	5.1851×10^8	3.3375×10^8	1.0370×10^9
média	1.4748×10^{12}	2.5043×10^{12}	2.1941×10^{12}
Desvio padrão	3.9275×10^{12}	9.5324×10^{12}	1.0038×10^{13}
Menor custo	2.4444×10^8	1.6692×10^8	2.2789×10^8

Caso 3 - Tamanho da população fixo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo

Na tabela 4.13 encontram-se os resultados obtidos quando a seleção torneio com valor mínimo 4 e o desvio padrão estão inclusos no indivíduo. Os resultados são próximos aos obtidos no caso 1.

Tabela 4.13 - Testes realizados no caso 3.

Taxa de recom- binação Simulações	100 %
1	5.4739×10^8
2	3.9934×10^8
3	4.1488×10^8
4	4.8852×10^8
5	9.2681×10^8
6	2.6501×10^8
7	1.2071×10^9
8	2.9765×10^8
9	3.9943×10^8
10	6.6815×10^8
11	4.2271×10^8
12	2.9494×10^9
13	2.8097×10^8
14	3.0949×10^8
15	4.4977×10^8
16	2.6458×10^9
17	1.6885×10^9
18	3.1142×10^8
19	5.5299×10^8
20	3.0835×10^8
21	4.5560×10^8
22	4.3634×10^8
23	2.2063×10^9
24	1.8871×10^9
25	2.1186×10^9
26	2.9451×10^8
27	4.0335×10^8
28	4.2642×10^8
29	1.7579×10^9

30	2.7866×10^8
Média	8.5995×10^8
Desvio padrão	7.8068×10^8
Menor custo	2.6501×10^8

Caso 4 - Tamanho da população fixo, seleção aleatória e desvio padrão auto-adaptativo

A tabela 4.14 representa os resultados obtidos com o algoritmo no qual os desvios padrões estão inclusos no indivíduo e a seleção é aleatória conforme a figura 4.7. Como observado, os resultados possuem ordem de grandeza muito elevada, devido ao modo de seleção.

Tabela 4.14 - Testes realizados no caso 4.

Taxa de recom- binação	100 %
Simulações	
1	7.5332×10^{18}
2	3.2934×10^{18}
3	6.0783×10^{18}
4	6.0575×10^{18}
5	4.3353×10^{18}
6	1.4310×10^{19}
7	3.9101×10^{18}
8	7.5928×10^{18}
9	1.0231×10^{19}
10	6.4892×10^{19}
11	2.7047×10^{18}
12	6.7839×10^{18}
13	3.9796×10^{18}
14	3.5561×10^{18}
15	2.1947×10^{19}

16	1.2296×10^{19}
17	4.0332×10^{18}
18	9.0607×10^{18}
19	5.6264×10^{18}
20	3.0162×10^{18}
21	1.0554×10^{18}
22	2.5316×10^{18}
23	3.4880×10^{18}
24	1.9325×10^{18}
25	3.1231×10^{18}
26	4.2823×10^{18}
27	2.0454×10^{19}
28	4.7630×10^{18}
29	2.3436×10^{18}
30	4.4451×10^{18}
Média	8.3219×10^{18}
Desvio padrão	1.1615×10^{19}
Menor custo	1.0554×10^{18}

Caso 5 – Tamanho da população fixo, seleção aleatória e desvio padrão auto-adaptativo

Os testes nos quais o algoritmo se aproxima das estratégias evolutivas, figura 4.8, mantendo seleção aleatória, sem recombinação e com mutação em todos os indivíduos, mostrou-se inadequado, devido à forma de seleção.

Tabela 4.15 - Testes realizados no caso 5.

Taxa de recombinação \ Simulações	0 %
1	2.9939×10^{18}
2	2.3912×10^{19}

3	8.4034×10^{18}
4	3.4363×10^{18}
5	5.0014×10^{18}
6	1.9702×10^{18}
7	4.0939×10^{18}
8	1.1799×10^{18}
9	1.5255×10^{19}
10	7.8960×10^{18}
11	6.0040×10^{18}
12	1.2119×10^{19}
13	6.6346×10^{18}
14	5.8888×10^{18}
15	8.6234×10^{18}
16	1.6275×10^{19}
17	8.4017×10^{18}
18	4.5753×10^{18}
19	1.7192×10^{19}
20	2.8050×10^{18}
21	6.9321×10^{18}
22	2.5301×10^{18}
23	4.8956×10^{18}
24	1.1994×10^{19}
25	2.5226×10^{18}
26	3.8602×10^{18}
27	5.7498×10^{18}
28	5.5429×10^{18}
29	4.9273×10^{18}
30	8.0175×10^{18}
média	7.3211×10^{18}
Desvio padrão	5.1284×10^{18}
Menor custo	1.1799×10^{18}

Caso 6 – Tamanho da população auto-adaptativo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo

Os resultados indicados na tabela 4.16 são do algoritmo que inclui o tamanho da população no indivíduo, isto é, o pseudocódigo da figura 4.9. O tempo de simulação é elevado e dois resultados são expostos: 100% de recombinação e 0% de recombinação.

Tabela 4.16 - Testes realizados com o caso 6.

Taxa de recom- binação	100 %	0 %
Simulações		
1	3.6888×10^8	6.1667×10^8
2	3.4386×10^8	2.4792×10^9
3	3.1319×10^9	7.3850×10^8
4	2.6916×10^8	5.8132×10^8
5	2.6189×10^8	5.2359×10^9
6	3.4327×10^8	4.7076×10^9
7	3.6976×10^8	3.0467×10^9
8	4.0428×10^8	3.1651×10^9
9	2.1737×10^8	4.8998×10^8
10	2.6700×10^9	1.7037×10^9
11	2.1871×10^8	2.4729×10^9
12	4.1912×10^8	2.6415×10^{13}
13	1.2637×10^{11}	5.7363×10^{12}
14	2.6736×10^8	6.1659×10^8
15	2.9843×10^8	6.0382×10^8
16	3.6940×10^8	2.6347×10^9
17	3.1052×10^8	5.6544×10^8
18	7.7665×10^9	9.0858×10^{14}
19	1.3884×10^9	4.6108×10^8
20	2.8084×10^8	1.8754×10^9
21	3.3130×10^8	5.4379×10^{11}

22	2.5177×10^8	1.2805×10^{15}
23	6.6334×10^8	1.9029×10^9
24	3.6586×10^8	8.9820×10^8
25	1.8176×10^9	5.0430×10^9
26	1.2876×10^{10}	1.4802×10^9
27	2.7496×10^8	7.8944×10^9
28	2.2711×10^8	2.7376×10^9
29	2.2443×10^8	1.4235×10^9
30	1.7232×10^8	3.0032×10^9
média	5.4425×10^9	7.4061×10^{13}
Desvio padrão	2.2606×10^{10}	2.7697×10^{14}
Menor custo	1.7232×10^8	4.8998×10^8

Caso 7 - Tamanho da população auto-adaptativo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo e correlação adaptativa

Não foi possível a obtenção de resultados desse caso, porque a mutação das vazões é dada pela equação 3.20.1. Para tal, fez-se uso da função *mvnrnd* do Matlab[®]. Essa função efetua a perturbação de média zero e variância dada pela matriz de covariância já mutada, C' , dada pelas equações 3.20.2 e 3.20.3. Entretanto, para que essa função funcione, C' precisa ser uma matriz simétrica, como é a matriz de covariância. Contudo, a matriz de covariância, nesse caso fica mal condicionada e produz, após truncamentos e arredondamentos internos no Matlab[®], autovalores negativos tornando-a virtualmente não positiva definida e conseqüentemente travando o programa antes que qualquer resultado razoável fosse encontrado.

Caso 8 - Tamanho da população auto-adaptativo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo, múltiplos cenários de vazões afluentes

Na tabela 4.17, estão apresentados os custos obtidos quando aplicado, no algoritmo do caso 6, as vazões incrementais estocásticas.

Tabela 4.17 - Testes realizados caso 8.

Taxa de recom- binação	100%
Simulações	
1	2.9351×10^{14}
2	2.9237×10^{14}
3	2.9627×10^{14}
4	2.8626×10^{14}
5	2.8651×10^{14}
6	2.8632×10^{14}
7	2.8654×10^{14}
8	2.9108×10^{14}
9	2.8663×10^{14}
10	2.8681×10^{14}
11	2.8616×10^{14}
12	2.8899×10^{14}
13	2.9600×10^{14}
14	2.9232×10^{14}
15	2.8975×10^{14}
16	2.8593×10^{14}
17	2.9338×10^{14}
18	2.8730×10^{14}
19	2.8639×10^{14}
20	2.8673×10^{14}
21	2.8862×10^{14}
22	2.8669×10^{14}

23	2.9229×10^{14}
24	2.9044×10^{14}
25	2.8818×10^{14}
26	2.8912×10^{14}
27	2.9883×10^{14}
28	3.0755×10^{14}
29	3.0269×10^{14}
30	2.8732×10^{14}
Média	2.9057×10^{14}
Desvio padrão	5.2116×10^{12}
Menor custo	2.8593×10^{14}

4.5.2 - Testes com recozimento simulado adaptativo difuso

Na tabela 4.18, estão apresentados os custos obtidos quando aplicado o recozimento simulado adaptativo difuso com vazões afluentes fixas, as médias de longo termo, MLT's.

Tabela 4.18 - Testes realizados com a MLT de vazões.

Simulações	Custos
1	1.2888×10^8
2	1.4501×10^8
3	1.2801×10^8
4	1.4498×10^8
5	1.4202×10^8
6	1.2489×10^8
7	1.2441×10^8
8	1.4025×10^8
9	1.3256×10^8
10	1.2899×10^8
11	1.2709×10^8
12	1.2882×10^8

13	1.2457×10^8
14	1.3096×10^8
15	1.3521×10^8
16	1.2861×10^8
17	1.2680×10^8
18	1.2624×10^8
19	1.3861×10^8
20	1.3019×10^8
21	1.3464×10^8
22	1.3008×10^8
23	1.3283×10^8
24	1.3285×10^8
25	1.3213×10^8
26	1.3123×10^8
27	1.3073×10^8
28	1.3013×10^8
29	1.3296×10^8
30	1.2623×10^8
Média	1.3170×10^8
Desvio padrão	5.5321×10^6
Menor custo	1.2441×10^8

Na tabela 4.19, estão apresentados os custos obtidos quando aplicado o recozimento simulado adaptativo difuso, utilizando as vazões incrementais estocásticas.

Tabela 4.19 - Testes realizados com múltiplos cenários de vazão.

Simulações	Custos
1	4.8675×10^{12}
2	4.8763×10^{12}
3	4.8721×10^{12}
4	4.8792×10^{12}

5	4.8906×10^{12}
6	4.8845×10^{12}
7	4.8892×10^{12}
8	4.8895×10^{12}
9	4.8998×10^{12}
10	4.8793×10^{12}
11	4.8640×10^{12}
12	4.9149×10^{12}
13	4.8685×10^{12}
14	4.8980×10^{12}
15	4.8761×10^{12}
16	4.9211×10^{12}
17	4.8692×10^{12}
18	4.8889×10^{12}
19	4.8703×10^{12}
20	4.8691×10^{12}
21	4.8762×10^{12}
22	4.8953×10^{12}
23	4.8872×10^{12}
24	4.8691×10^{12}
25	4.8952×10^{12}
26	4.8872×10^{12}
27	4.8988×10^{12}
28	4.8777×10^{12}
29	4.8976×10^{12}
30	4.8969×10^{12}
Média	4.8850×10^{12}
Desvio padrão	1.4011×10^{10}
Menor custo	4.8640×10^{12}

4.6 - Análise gráfica

Nessa seção a operação do sistema será ilustrada através de três gráficos: o de geração segmentada, o de armazenamento dos reservatórios de acumulação e do percentual de utilização do volume útil dos reservatórios de acumulação. Os casos ilustrados são o caso 1, caso 2, caso 3 e o caso 6. Os demais casos, em estratégias evolutivas, não obtiveram soluções viáveis sofrendo diversas violações, não justificando a análise gráfica dos mesmos.

Caso 1 - Tamanho da população fixo, tamanho do torneio fixo e desvio padrão determinístico

As figuras 4.12, 4.13 e 4.14, ilustram a melhor política de operação das usinas de reservatório de acumulação que obteve o custo de operação do sistema de R\$ 134.767.495,42, para o caso 1. Através da figura 4.12, pode-se observar que a demanda de carga média de 8500MW está sendo atendido, sem violações de geração. Na figura 4.13, vê-se que a utilização dos reservatórios foi otimizada, visto que os reservatórios atingiram os seus picos de armazenamento ao fim da época de cheia de cada bacia.

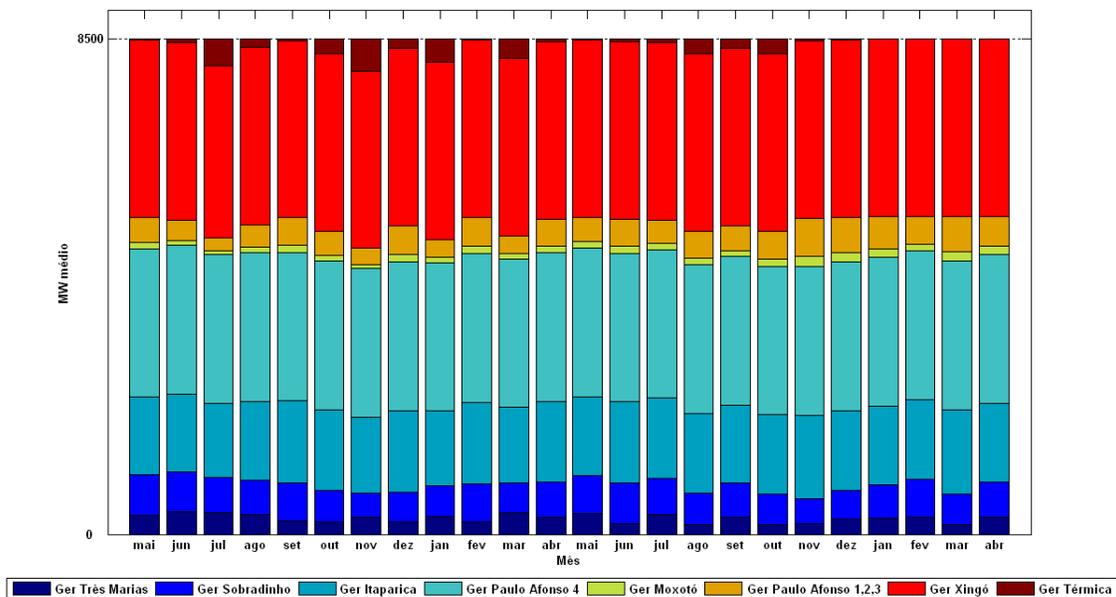


Figura 4.12 - Geração segmentada por fonte.

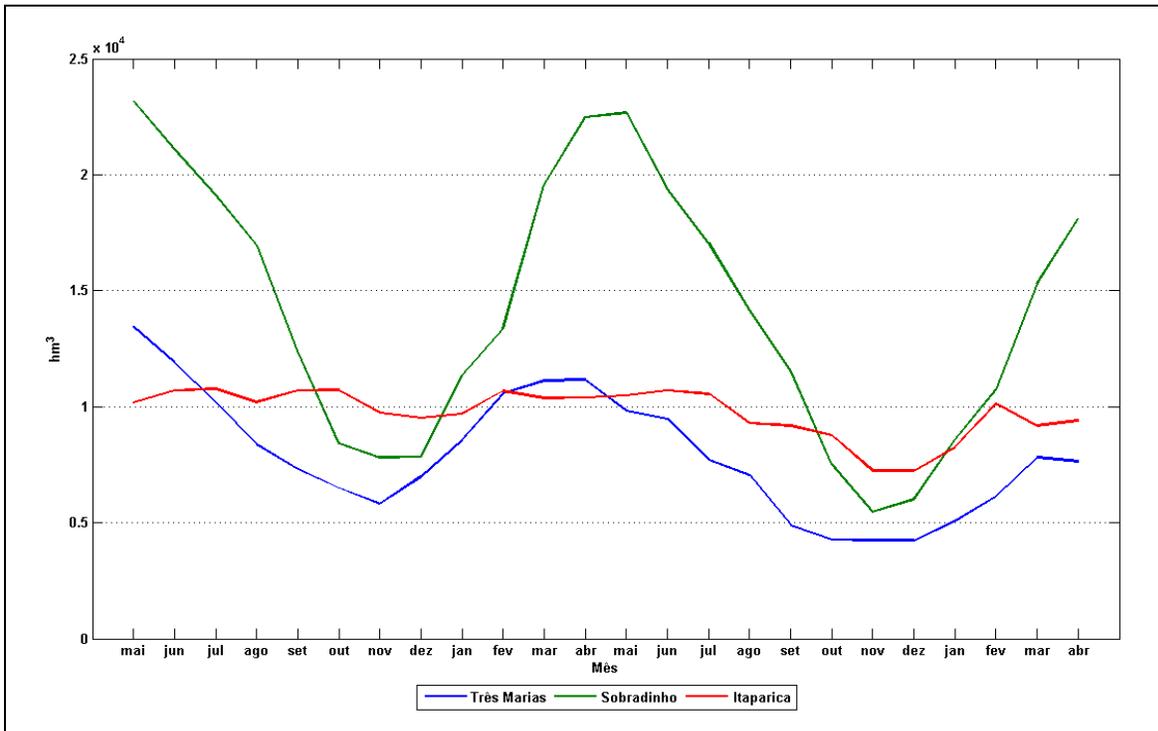


Figura 4.13 - Armazenamento dos reservatórios em hm³.

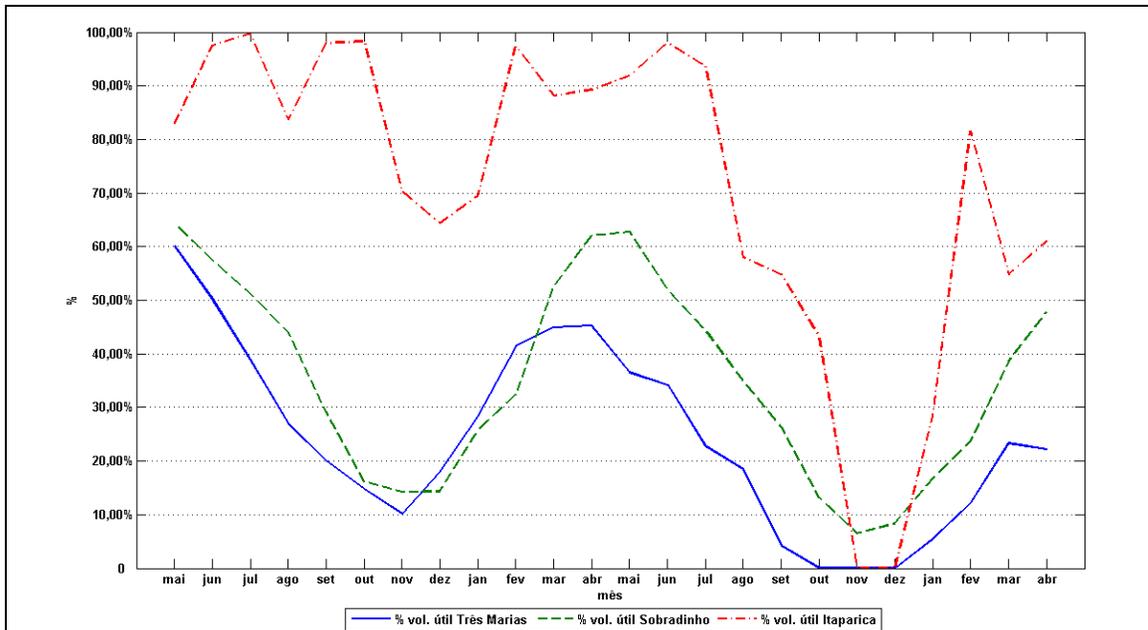


Figura 4.14 - Armazenamento percentual do volume útil.

Caso 2 - Tamanho da população fixo, seleção torneio auto-adaptativo e desvio padrão determinístico

O menor custo de operação do sistema encontrado no caso 2 foi de R\$ 166.922.753,56. As figuras 4.15, 4.16 e 4.17 apresentam a política de operação escolhida. O custo de operação nesse caso foi superior ao caso 1, a demanda foi atendida, como visto na figura 4.15. No entanto, somente o reservatório de Sobradinho atingiu o seu pico no final do período de cheia, mês de maio, como visto na figura 4.16.

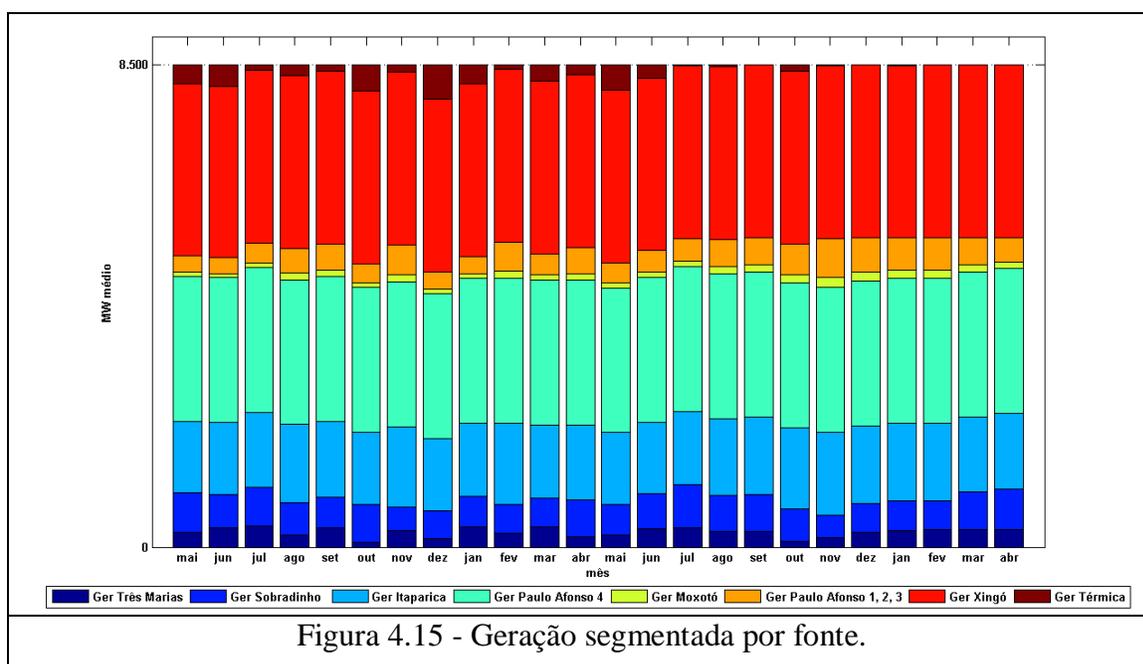


Figura 4.15 - Geração segmentada por fonte.

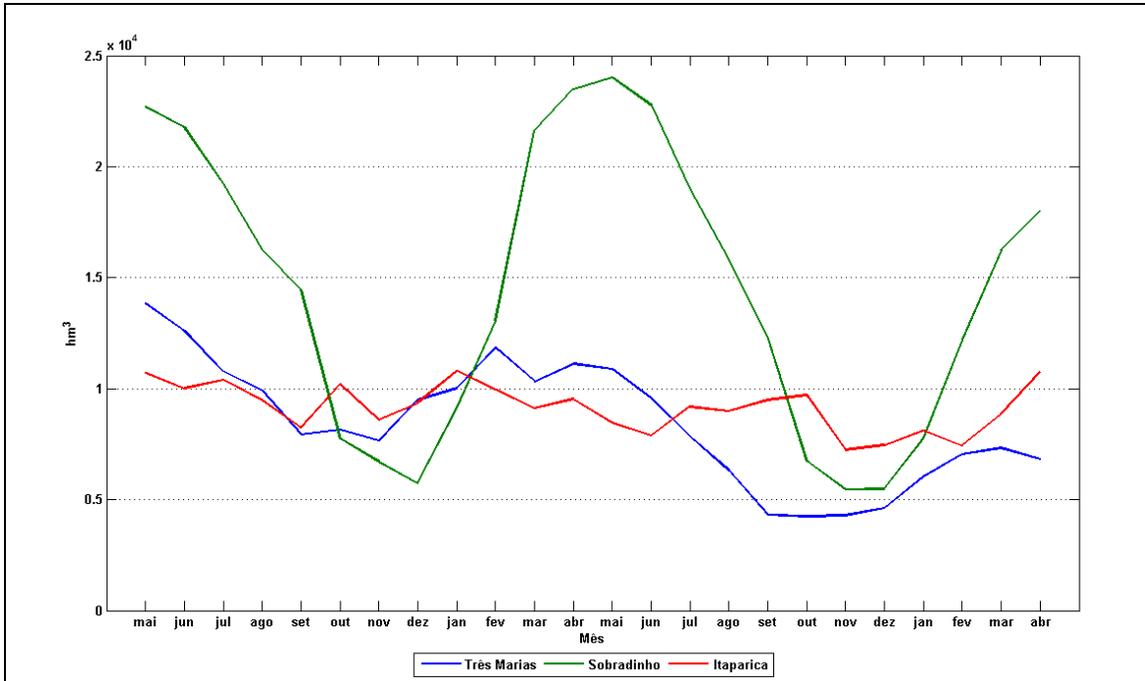


Figura 4.16 - Armazenamento dos reservatórios em hm³.

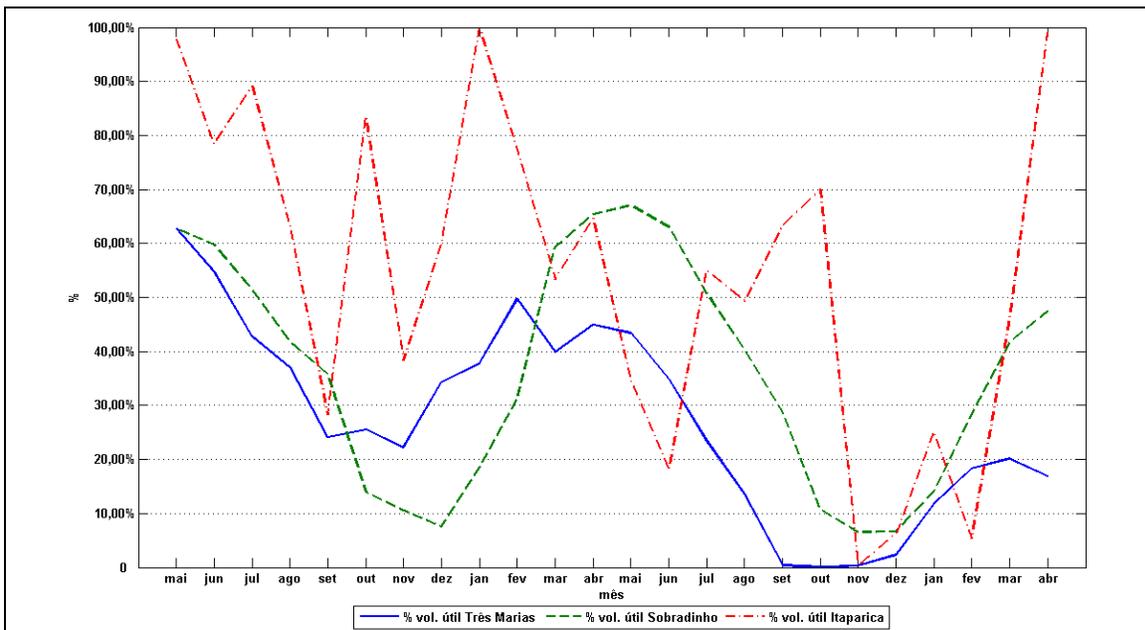
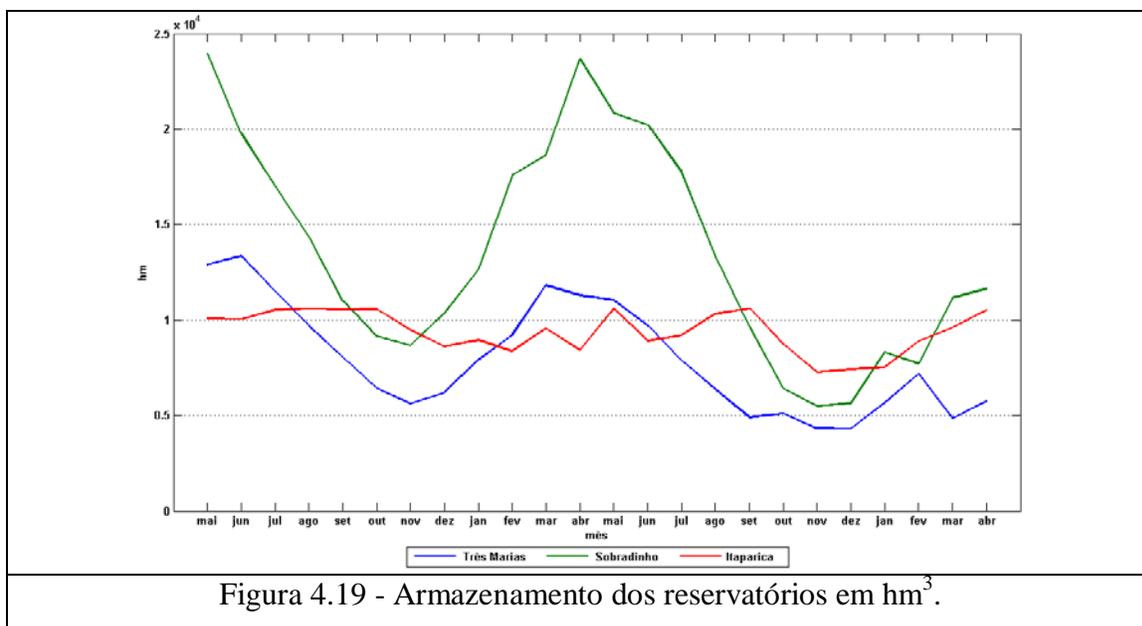
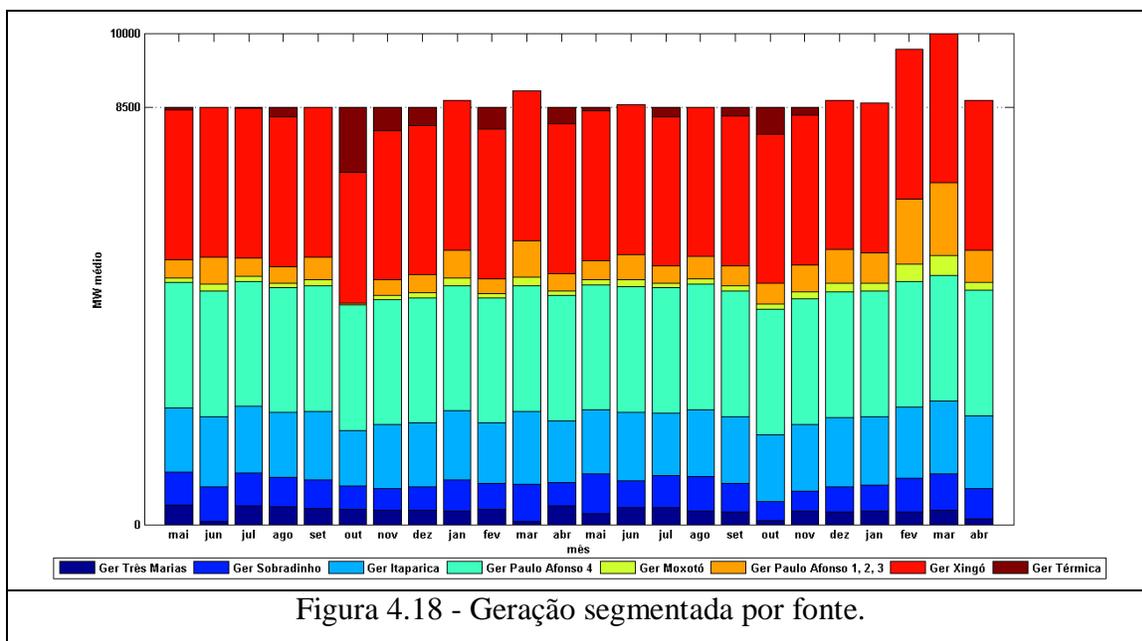


Figura 4.17 - Armazenamento percentual do volume útil.

Caso 3 - Tamanho da população fixo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo

As figuras 4.18, 4.19 e 4.20 apresentam a melhor política operativa no caso 3, com o custo de R\$ 265.008.142,63. Na figura 4.18, nota-se que no final do período de 24 meses, houve uma violação na geração, que foi penalizada pela função custo, elevando assim o custo operativo do sistema.



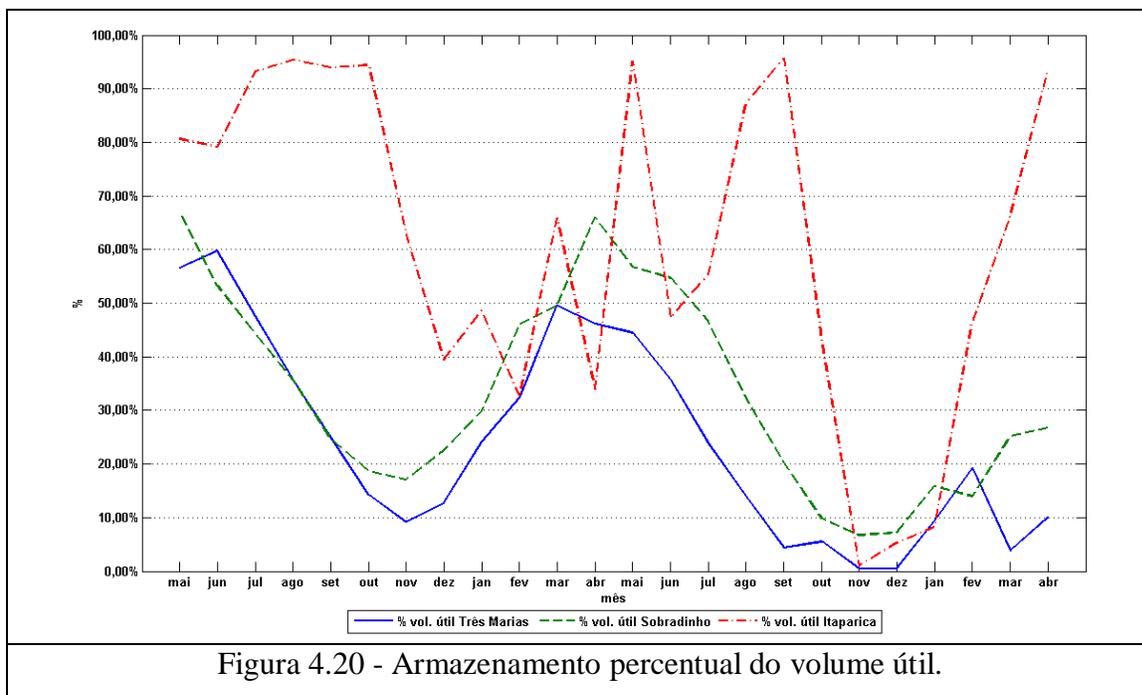
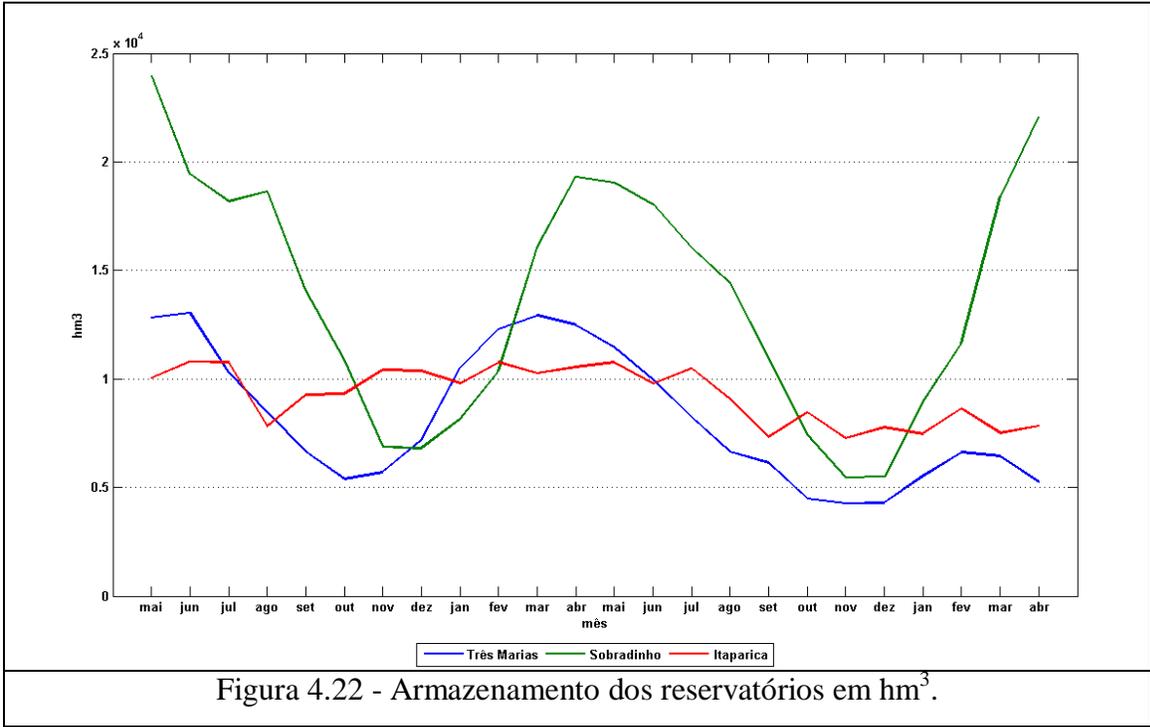
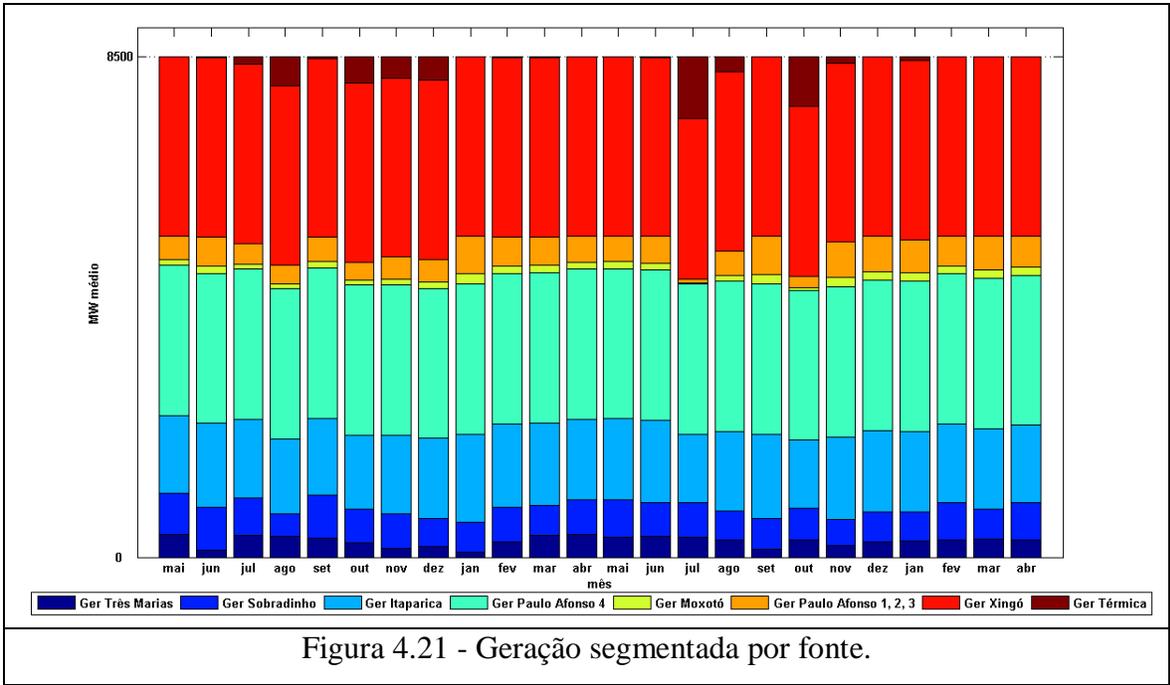


Figura 4.20 - Armazenamento percentual do volume útil.

Caso 6 – Tamanho da população auto-adaptativo, seleção torneio auto-adaptativo e desvio padrão auto-adaptativo

As figuras 4.21, 4.22 e 4.23 mostram a melhor operação do sistema para o caso 6 ao custo de R\$ 172.320.942,20. A figura 4.21 apresenta as gerações de cada usina e o atendimento da demanda de carga. Na figura 4.22 visualiza-se a que o pico de água nos reservatórios de Sobradinho e Três Marias coincidem com o final do período de cheias, o que reflete na redução do menor custo encontrado nesse caso em relação ao custo encontrado no caso 3.



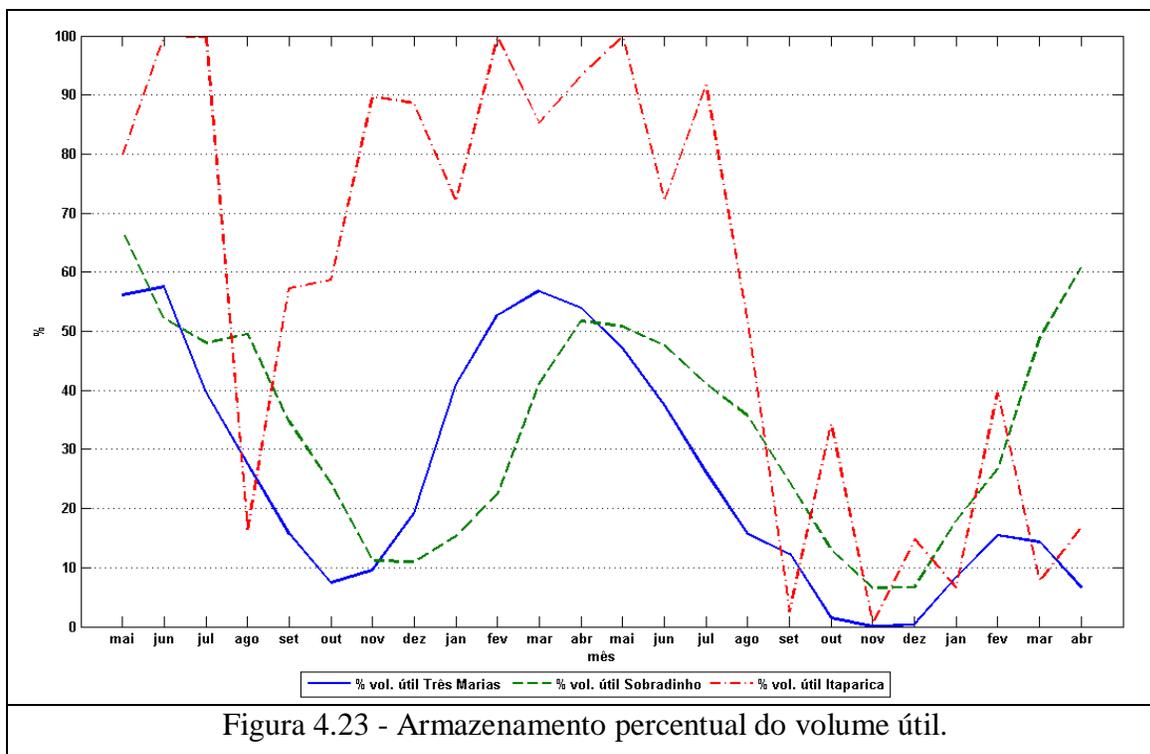


Figura 4.23 - Armazenamento percentual do volume útil.

4.7 - Análise dos resultados

Os resultados obtidos nesse capítulo necessitam de análise com o objetivo de avaliá-los quanto a sua viabilidade e compará-los com outras meta-heurísticas empregadas no mesmo sistema-teste. Na tabela 4.20 são apresentados os melhores resultados e as médias gerais dos custos obtidos com as oito configurações testadas com a meta-heurística estratégias evolutivas, sendo o oitavo com múltiplas vazões afluentes.

Tabela 4.20 - Resultados estratégias evolutivas.

	média geral	desvio padrão	desvio/média (%)
Caso 1	2.0800×10^8	4.2475×10^7	20.4212
Caso 2	7.8328×10^{12}	2.0577×10^{12}	26.2707
Caso 3	8.5995×10^8	7.8068×10^8	90.7818
Caso 4	8.3219×10^{18}	1.1615×10^{19}	139.5748
Caso 5	7.3211×10^{18}	5.1284×10^{18}	70.0499
Caso 6	3.7033×10^{13}	1.3850×10^{14}	373.9788
Caso 8	2.9057×10^{14}	5.2116×10^{12}	1.7936

Através da análise dos resultados, nota-se a grande influência do modo de seleção, pois há uma elevação da ordem de 10^{10} nos resultados que provém dos testes realizados com modo de seleção aleatória. A maior robustez encontra-se no Caso 1, assim como o menor resultado absoluto e a melhor média. Destaca-se que o caso 1 possui parâmetros fixos.

Na tabela 4.21, encontram-se as melhores médias para cada caso, ou seja, a melhor configuração para cada caso são elas: caso 1- taxa de recombinação de 95%, caso 2 - taxa de recombinação de 100% e caso 6 - taxa de recombinação de 100%, os casos 3, 4 e 5 possuem apenas uma taxa de recombinação. Na tabela encontram-se também os menores custos, desvios padrões e desvio/média (coeficiente de variação) correspondentes às configurações de menores médias citadas anteriormente.

Tabela 4.21 - melhores resultados das estratégias evolutivas com vazões determinísticas

	Menor média	Menor custo	Desvio padrão	desvio/média (%)
Caso 1 – 95%	1.9473×10^8	1.4153×10^8	4.5522×10^7	23.3767
Caso 2 – 100%	1.4748×10^{12}	2.4444×10^8	3.9275×10^{12}	266.3102
Caso 3	8.5995×10^8	2.6501×10^8	7.8068×10^8	90.7818
Caso 4	8.3219×10^{18}	1.0554×10^{18}	1.1615×10^{19}	139.5748
Caso 5	7.3211×10^{18}	1.1799×10^{18}	5.1284×10^{18}	70.0499
Caso 6 – 100%	5.4425×10^9	1.7232×10^8	2.2606×10^{10}	415.3706

A partir da tabela 4.21 nota-se que a auto-adaptação do torneio (casos 2, 3 e 6), eleva a média dos resultados obtidos em comparação ao torneio fixo (caso 1). O tamanho mínimo do torneio também influenciou na média dos resultados. A média do caso 2 (tamanho mínimo do torneio igual a 2), é superior a média dos casos 3 e 6 (tamanho mínimo do torneio igual a 4). A inclusão do tamanho da população como gene no indivíduo (caso 6), elevou a média em relação aos resultados do caso 3, que também possui desvio padrão incluso no indivíduo e seleção com torneio mínimo igual a 4. Entretanto, o caso 6 obteve um menor custo, comparado ao menor custo do caso 3.

Na tabela 4.22, estão os menores custos obtidos em cada caso. O menor custo no caso 1 está na probabilidade de recombinação de 100%, assim como no caso 6. No caso 2, o menor custo está na probabilidade de recombinação de 95%. O menor custo entre todos os casos com vazão determinística aplicando estratégias evolutivas é encontrado no caso 1.

Tabela 4.22 - Menores resultados estratégias evolutivas com vazões determinísticas.

	Menor custo
Caso 1 - 100%	1.3477×10^8
Caso 2 - 95%	1.6692×10^8
Caso 3	2.6501×10^8
Caso 4	1.0554×10^{18}
Caso 5	1.1799×10^{18}
Caso 6 – 100%	1.7232×10^8

Na tabela 4.2.3 estão os melhores resultados e suas respectivas médias quando se aplicou a meta-heurística recozimento simulado adaptativo difuso, que possui controle de parâmetros adaptativo.

Tabela 4.23 - Resultados recozimento simulado adaptativo difuso.

	Vazões Determinísticas	Vazões Estocásticas
média	1.3170×10^8	4.8850×10^{12}
desvio padrão	5.4422×10^6	1.3784×10^{10}
menor	1.2441×10^8	4.8640×10^{12}
desvio/média	4.1323%	0.2821 %

Nas tabelas 4.24 e 4.25 são comparados os resultados obtidos pelas estratégias evolutivas e recozimento simulado adaptativo difuso. Com vazões determinísticas, a tabela 4.24, o caso de melhor média em estratégias evolutivas (caso 1 com 95% de probabilidade de recombinação) e menor custo e desvio padrão, associados a essa configuração e os resultados obtidos com recozimento simulado adaptativo difuso.

Tabela 4.24 - Comparação para o cenário determinístico.

	Estratégias Evolutivas Caso 1	Recozimento Simulado Adaptativo Difuso
média	1.9473×10^8	1.3170×10^8
desvio padrão	4.5522×10^7	5.4422×10^6
menor	1.4153×10^8	1.2441×10^8
desvio/média	23.3767 %	4.1323 %

Com vazões estocásticas, compara-se o caso 8 das estratégias evolutivas e os resultados obtidos com recozimento simulado adaptativo difuso, tabela 4.25.

Tabela 4.25 - Comparação para o cenário estocástico.

	Estratégias Evolutivas Caso 8	Recozimento Simulado Adaptativo Difuso
média	2.9057×10^{14}	4.8850×10^{12}
desvio padrão	5.2116×10^{12}	1.3784×10^{10}
menor	2.8593×10^{14}	4.8640×10^{12}
desvio/média	1.7936%	0.28216 %

Essas tabelas mostram que os resultados obtidos com recozimento simulado adaptativo difuso possuem menores médias, desvios padrões, menor custo e menor coeficiente de variação.

Na tabela 4.26 encontram-se os melhores resultados obtidos em [1] com a aplicação de algoritmo genético, enxame de partículas e recozimento simulado nas colunas 1, 2 e 3. Nas colunas 4 e 5 da mesma estão os melhores resultados obtidos na aplicação das estratégias evolutivas e no recozimento simulado adaptativo difuso para o caso das vazões afluentes determinísticas. No caso das estratégias evolutivas, o caso exposto é o que tem melhor média, o caso 1 com a taxa recombinação de 95%.

Tabela 4.26 - Comparação dos resultados.

	Algoritmo Genético [1]	Enxame de Partículas [1]	Recozimento Simulado [1]	Estratégias Evolutivas	Recozimento Simulado Adaptativo Difuso
média	1.8779×10^8	1.7624×10^8	1.4571×10^8	1.9473×10^8	1.3170×10^8
desvio padrão	1.0701×10^7	2.3419×10^7	1.0538×10^7	4.5522×10^7	5.4422×10^6
desvio/média	23.3767 %	266.3102 %	90.7818 %	139.5748 %	70.0499%
menor	1.7140×10^8	1.3433×10^8	1.2829×10^8	1.4153×10^8	1.2441×10^8

Analisando as tabelas 4.24, 4.25 e 4.26, pode-se observar que a meta-heurística mais robusta é o recozimento simulado adaptativo, pois apresentou os menores valores de custo de operação, melhores médias com menor variância nos resultados das simulações. No entanto, os resultados encontrados com estratégias evolutivas são competitivos e próximos aos encontrados em outras meta-heurísticas aplicadas no mesmo sistema-teste, como vemos na tabela 4.26. A ampliação dos estudos da utilização das estratégias evolutivas na solução de problemas de coordenação hidrotérmica pode torná-la uma ferramenta mais robusta para esse tipo de aplicação.

Sobre o controle dos parâmetros, o controle de parâmetros adaptativo mostrou-se mais eficiente para o problema tratado: a coordenação hidrotérmica em médio prazo para um sistema teste desse porte. As meta-heurísticas que possuem esse tipo de controle são: o recozimento simulado difuso e enxame de partículas.

Entretanto, é importante salientar que o controle auto-adaptativo é bastante interessante por não necessitar de ajustes prévios em parâmetros estratégicos, o demanda tempo para a investigação do melhor ajuste para os parâmetros, bem como um conhecimento prévio do usuário do problema a ser tratado.

Capítulo 5

Conclusões

A ampliação do consumo de energia elétrica demanda um aumento na geração de energia. Devido aos elevados custos associados às novas construções de usinas, há uma grande necessidade de um maior aproveitamento do parque energético existente. O despacho hidrotérmico, subdividido em coordenação hidrotérmica, pré-despacho e despacho econômico, possibilita esse maior aproveitamento através do despacho ótimo das usinas térmicas e hidrelétricas disponíveis. Associado a isso, minimiza os custos operativos, lidando com um grande número de incertezas e funções de comportamento complexo.

A presente dissertação se propôs a aplicar duas meta-heurísticas para a coordenação hidrotérmica de um sistema-teste localizado na bacia do São Francisco. Houve uma ampliação dos estudos iniciados na dissertação [1], acrescentando às meta-heurísticas lá estudadas, as estratégias evolutivas e recozimento simulado adaptativo difuso, além da inclusão de estudos referentes a vazões afluentes de múltiplos cenários.

As estratégias evolutivas e o recozimento simulado adaptativo difuso foram escolhidos, pois são técnicas que possibilitam a ampla exploração do espaço de soluções e também o controle dos parâmetros de busca.

Os testes realizados tinham como finalidade a coordenação hidrotérmica de um sistema com carga de 8.500 MW-médios por um período de dois anos. Sobre a aplicação das estratégias evolutivas com vazões afluentes determinísticas, testes preliminares foram executados com o objetivo de que alguns parâmetros fossem definidos. Ao final dessa etapa ficou estabelecido o valor de ρ (número de pais que geram um filho), o tipo de

recombinação e de seleção, número de gerações e número de pais que formam a população inicial. Dessa forma diversos testes foram realizados para os quais, pseudocódigo e resultados foram expostos no capítulo 4.

Alguns aspectos merecem destaque como a inclusão de parâmetros (tamanho do torneio, tamanho da população e desvios padrões) como genes no indivíduo, ou seja, a auto-adaptação. Essas inclusões influenciaram a média dos testes, contudo os menores custos encontram-se na mesma ordem de grandeza. Vale ressaltar também os resultados produzidos pela variação do tamanho da seleção torneio, a princípio o torneio foi fixado em 4. Posteriormente, o torneio foi incluso no indivíduo e possuía variação de valores, mínimo e máximo, pré-estabelecidos. Os valores mínimos de torneio influenciaram diretamente no resultado.

A taxa de recombinação da maioria dos testes foi de 100%, no entanto nos dois primeiros testes outras taxas de recombinação foram exploradas. A respeito do modo de seleção, dois tipos foram utilizados, a seleção torneio e a seleção aleatória. A seleção aleatória se mostrou insatisfatória, pois a ordem de grandeza dos custos obtidos foi bastante elevada, como esperado, enquanto a seleção torneio se mostrou mais adequada gerando custos dentro da faixa de valores esperados.

Em suma, nota-se que a principal influência nos resultados das estratégias evolutivas está relacionada ao tipo de seleção, visto que os casos nos quais a seleção aleatória (caso 4 e 5) foi aplicada apresentaram soluções não viáveis. Os casos nos quais a seleção aplicada foi o torneio, a que possuía torneio fixo (caso 1) apresentou maior robustez. Quando o torneio foi incluso no indivíduo, os resultados mais robustos se mostraram quando o torneio mínimo fixado era o torneio 4 (caso 3). A inclusão do tamanho da população (caso 6) elevou a média de valores, no entanto não deve ser descartada, pois ela diminuiu a quantidade de parâmetros que devem ser ajustados pelo usuário. A recombinação e a mutação influenciaram de forma menos determinante nos resultados obtidos.

Os resultados obtidos com a aplicação do recozimento simulado adaptativo difuso foram melhores, em relação ao mínimo, média e desvio padrão, do que todas as meta-heurísticas aplicadas até então. Quanto à utilização de vazões afluentes de múltiplos cenários, é perceptível que o recozimento simulado adaptativo difuso teve melhor desempenho em comparação com as estratégias evolutivas, não somente em relação ao menor custo como também, melhor média e melhor robustez.

Apesar do melhor desempenho do recozimento simulado adaptativo, é válido destacar a dificuldade de configurar simultaneamente os diversos parâmetros existentes e, devido a isso, há necessidade de que o usuário tenha um prévio conhecimento do algoritmo. O controle dos parâmetros de busca em algoritmos evolutivos é o foco de diversos estudos [32], [33], [34], pois o ajuste de parâmetros manualmente é algo complexo que demanda tempo e geralmente conduz a soluções sub-ótimas. As meta-heurísticas utilizadas nessa dissertação possuem parâmetros de busca adaptativos com regras fixas (recozimento simulado adaptativo difuso) e auto-adaptativos (estratégias evolutivas). Isto faz com que os resultados gerados pelo algoritmo sejam utilizados no processo de busca, o que diminui as chances de que espaços não promissores sejam explorados. Os algoritmos que possuem parâmetros de busca auto-adaptativos necessitam de menor quantidade de ajustes prévios em comparação aos adaptativos, permitindo que usuários sem domínio do problema tratado possam utilizá-los com mais facilidade.

Em análise geral podemos concluir que os custos de operação encontrados em alguns casos estiveram próximos aos obtidos no estudo anterior [1], o que valida as estratégias evolutivas e o recozimento simulado adaptativo como uma alternativa para a solução de problemas de coordenação hidrotérmica do porte testado para vazões afluentes fixas. Entretanto, apesar dos resultados encontrados serem considerados razoáveis, há necessidade de melhorias para aplicação das mesmas meta-heurísticas quando se trata de vazões afluentes de múltiplos cenários.

Como sugestão para trabalhos futuros na aplicação de estratégias evolutivas sugere-se a inserção da matriz de covariância no indivíduo, utilizando para tal outra linguagem de programação, visto que o Matlab® apresentou restrições nessa questão e a inclusão da taxa de recombinação como um gene no indivíduo também pode ser explorada. Outra proposta interessante seria a melhoria dos resultados atingidos com as múltiplas vazões afluentes através de melhor ajuste em parâmetros de controle, que pode ser tratado via solução hierárquica, isto é, pesquisa no espaço de parâmetros de controle através de meta-heurísticas também. Outra sugestão é a aplicação dessas meta-heurísticas em sistemas-teste de maior porte.

Referências Bibliográficas

- [1] AMENDOLA, Alexandre Ferreira, “*Meta-Heurísticas de Otimização Aplicação à Coordenação Hidrotérmica*”, Dissertação de Mestrado, Programa de Engenharia Elétrica, Coordenação dos Programas de Pós-Graduação de Engenharia, Universidade Federal do Rio de Janeiro, Junho 2007.
- [2] SOARES, S.; LYRA, C.; TAVARES, H., “*Optimal Generation Scheduling of Hydrothermal Power Systems*”, IEEE Transactions on Power Apparatus and Systems, Vol. PAS – 99, N° 3, pp. 1107-1118, May/June 1980.
- [3] PEREIRA, M. V. F.; PINTO, L. M. V. G., “*A Decomposition Approach to the Economic Dispatch of Hydrothermal Systems*”, IEEE Transactions on Power Apparatus and Systems, Vol. PAS – 101, N° 10, pp. 3851-3860, October 1982.
- [4] LYRA, C.; TAVARES, H.; SOARES, S., “*Modeling and Optimization of Hydrothermal Generation Scheduling*”, IEEE Transactions on Power Apparatus and Systems, Vol. PAS – 103, N° 8, pp. 2126-2133, August 1984.
- [5] SHAW, John J.; GENDRON, Robert F.; BERTSEKAS, Dimitri P., “*Optimal Scheduling of Large Hydrothermal Power Systems*”, IEEE Transactions on Power Apparatus and Systems, Vol. PAS – 104, N° 2, pp. 286-294, February 1985.
- [6] BISSONNETE, V.; LAFOND, L.; CÔTÉ, G., “*A Hydrothermal Scheduling for the Hydro-Quebec Production System*”, IEEE Transactions on Power Systems, Vol. PWRS – 1, N° 2, pp. 204-210, May 1986.
- [7] CARVALHO, M.F.; SOARES, S., “*An Efficient Hydrothermal Scheduling Algorithm*”, IEEE Transactions on Power Systems, Vol. PWRS - 2, N° 3, pp. 537-542, August 1987.

- [8] CARNEIRO, A. A. F. M.; SOARES, S.; BOND, P. S., “*A Large Scale Application of an Optimal Deterministic Hydrothermal Scheduling Algorithm*”, IEEE Transactions on Power Systems, Vol. 5, Nº 1, pp. 204-211, February 1990.
- [9] CONEJO, A. J.; CARAMANIS, M. C.; BLOOM, J. A., “*An Efficient Algorithm for Optimal Reservoir Utilization in Probabilistic Production Costing*”, IEEE Transactions on Power Systems, Vol. 5, Nº 2, pp. 439-447, May 1990.
- [10] SOARES, S.; CARNEIRO, A. A. F. M., “*Optimal Operation of Reservoirs for Electric Generation*”, IEEE Transactions on Power Delivery, Vol. 6, Nº 3, pp. 1101-1107, July 1991.
- [11] LI, Chao-an; JAP, Philip J.; STREIFFERT, Dan L., “*Implementation of Network Flow Programming to the Hydrothermal Coordination in an Energy Management System*”, IEEE Transactions on Power Systems, Vol. 8, Nº 3, pp. 1045-1053, August 1993.
- [12] LI, Chao-an; HSU, Eric; SVOBODA, Alava J.; TSENG, Chung-Li; JOHNSON, Raymond B., “*Hydro Unit Commitment in Hydro Thermal Optimization*”, IEEE Transactions on Power Systems, Vol. 12, Nº 2, pp. 764-769, May 1997.
- [13] CIGOGNA, Marcelo Augusto, *Modelo de Planejamento da Operação Energética de Sistemas Hidrotérmicos a Usinas Individualizadas Orientado por Objetos*, Dissertação de Mestrado, Departamento de Engenharia de Sistemas, Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, Fevereiro 1999.
- [14] ENCINA, Anastácio Sebastián Arce, “*Um modelo de otimização do despacho de máquinas em usinas hidrelétricas*”, Dissertação de Mestrado, Departamento de Engenharia de Sistemas, Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, Novembro 1999.

[15] MACEIRA, Maria Elvira P.; DUARTE, Vitor S.; MARCATO, Rachel M.; MARCATO, André Luis M.; DA COSTA, Vander M., “*Comparação entre Abordagens Estocásticas e Determinísticas no Planejamento da Operação de Médio Prazo de Sistemas Hidrotérmicos Interligados*”, XVII Seminário Nacional de Produção e Transmissão de Energia Elétrica, Outubro 2003

[16] PROVENÇANO, Felipe, “*Despacho Econômicos em Usinas Térmicas*”, Dissertação de Mestrado, Departamento de Engenharia de Sistemas, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Março 2003.

[17] HUMPIRI, Carolina Janet Pastor, *Estratégias Evolutivas no Planejamento Energético da Operação de Sistemas Hidrotérmicos de Potência*, Dissertação de Mestrado, Departamento de Engenharia de Sistemas, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Julho 2005.

[18] CASTRO, Marco A.A.; CARNEITO, Adriano A.F.M.; ANDRADE, Marinho G., “*Programação dinâmica estocástica aplicada em sistemas hidrotérmicos com representação individualizada das usinas hidroelétrica*”, X Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Maio 2006.

[19] OLIVEIRA JUNIOR, Hime Aguiar e, “*Projeto de Filtros Digitais e Separação de Fontes Usando Fuzzy Adaptive Simulated Annealing*”, Tese de Doutorado, Programa de Engenharia Elétrica, Coordenação dos Programas de Pós-Graduação de Engenharia, Universidade Federal do Rio de Janeiro, Junho 2008.

[20] www.ons.org.br/conheca_sistema/o_que_e_sin.aspx, visitado em 06 de abril de 2009.

[21] <http://www.cepel.br/servicos/descprog.shtm>, visitado em 25 de maio de 2009.

[22] N.R.XAVIER, L.; LIMA, A. L. D. S.; COSTA, F. da S.; MACEIRA, M. E. P., “*Aprimoramento da Modelagem da Função de Produção Energética das Usinas Hidroelétricas do Modelo Decomp: Metodologia e Resultados*”, XVIII Seminário Nacional de Produção e Transmissão de Energia Elétrica, Curitiba, 2005.

[23] OLIVEIRA, S. A. de, “*Metaheurísticas Aplicadas ao Planejamento da Expansão da Transmissão de Energia Elétrica em Ambiente de Processamento Distribuído*”, Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Outubro 2004.

[24] BECCENERI, J. C., “*Meta heurísticas bio-inspiradas aplicadas a problemas de otimização*”, Grupo de Pesquisa Operacional, Laboratório Computação Matemática Aplicada. Disponível em <http://www.lac.inpe.br/~becceneri/palestras/Meta-heurísticas.pdf>

[25] BOX, George E. P, “*Evolutionary operation: A method for increasing industrial productivity*”, Applied Statistics, Vol. 6, N° 2, pp. 81-101, June 1957.

[26] FRIEDBERG, R. M., “*A learning machine: Part i*”, IBM Journal, pp. 2-13, January 1958.

[27] BREMERMAN, H. J., “*Optimization through evolution and recombination*”, M.C. Yovits, G.T. Jacobi, and D.G. Goldstein, editors, Self-organizing systems, Spartan, Washington D.C., pp. 93-106, 1962.

[28] FOGEL, L. J.; OWENS, A. J.; WASH, M. J., “*Artificial Intelligence Through Simulated Evolution*”, John Wiley & Sons, 1966.

[29] HOLLAND, J. H., “*Outline for a logical theory of adaptive systems*”, Journal of the ACM, Volume 9, Issue 3, pp. 297 – 314, July 1962.

[30] HOLLAND, J. H., "*Adaptation in Natural and Artificial Systems - An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*", The University of Michigan, 1975.

[31] EIBEN, A.I; SMITH J.E., "*Introduction to Evolutionary Computing*", Springer, Capítulo 4, páginas 71-88, 2003.

[32] EIBEN, A.E.; HINTERDING, R.; MICHAELEWICZ, Z., "*Parameter Control in Evolutionary Algorithms*", IEEE Transactions on Evolutionary Computation, vol. 3, N° 2, pp. 124-141, July 1999.

[33] EIBEN, A.E.; SCHUT, M. C.; DE WILDE, A. R., "*Is Self-Adaptation of Selection Pressure and Population Size Possible – a case study*", PPSN 2006: The 9th International Conference on Parallel Problem Solving from Nature, páginas 900-909, 2006.

[34] BACK, T., "*Self Adaptation in Genetic Algorithm*", Proceeding of the 1st ECAL eds, Varela F J and Bourgine P, MIT Press, páginas 263-271, 1992.

[35] GOMES, J. G. R., "*Apostila de Otimização Natural – Simulated Annealing*", PEE, COPPE, Universidade Federal do Rio de Janeiro, Março 2007.

[36] BOYD, R.; RECHARSON, P., "*Culture and the Evolutionary Process*", University of Chicago Press, 1985.

[37] KENNEDY, J.; EBERHART, R., "*Particle Swarm Optimization*", Proceedings of IEEE International Conference on Neural Networks, vol. IV, pp 1942-1948, Perth, Australia, 1995.

[38] SHI, Y. e EBERHART, R., "*A Modified Particle Swarm Optimizer*", Proceedings of the IEEE International Conference on Evolutionary Computation (ICEC'98), pp. 69-73, Anchorage, May 1998.

- [39] RATNAWEERA, A.; HALGAMUGE, S. K.; WATSON, H. C., “*Self-Organizing Hierarchical Particle Swarm Optimizer With Time-Varying Acceleration Coefficients*”, IEEE Transactions on Evolutionary Computation, Volume 8, N° 3, pp. 240- 255, June 2004.
- [40] MÜLLER, Viviane, “*Otimização de Layouts Industriais através do Método Enxame de Partículas*”, Dissertação de Mestrado, Programa de Pós Graduação Sistema de Processos Industriais, Universidade de Santa Cruz do Sul, Janeiro 2007.
- [41] CLERC, M.; KENNEDY, J., “*The Particle Swarm – Explosion, Stability and Convergence in a Multidimensional Complex Space*”, IEEE Transactions on Evolutionary Computation, vol. 16, N° 1, pp. 125-138, February 2002.
- [42] INGBER, L., “*Adaptative Simulated Annealing (ASA): Lessons Learned*”, Control and Cybernetics, Vol.25, N° 1, pp. 33-54, 1996. Disponível em: http://www.ingber.com/asa96_lessons.pdf
- [43] OLIVEIRA JR, H.A., “*Lógica Difusa – Aspectos Práticos e Aplicações*”, 1ª Ed, Rio de Janeiro, Editora Interciência, 1999.
- [44] SCHWEFEL, Hans Paul; “*Numerical Optimization of Computer Models*”, Wiley, Chichester, 1981.
- [45] SCHWEFEL, Hans Paul; “*Evolution and Optimum Seeking*”, Wiley, New York, 1995.
- [46] www.ons.org.br/conheca_sistema/mapas_sin.aspx, visitado em 27 de abril de 2009.
- [47] FALCÃO, D. M., “*Apostila do curso Análise de Redes Elétricas*”, Programa de Engenharia Elétrica, COPPE, Universidade Federal do Rio de Janeiro, pp. 146-147, 2003.

Anexo

Função Adequabilidade

```
function [CT,ct_mes,melhor]=custo_total_backup(vazao_defluente);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% dados do sistema
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%Vazão incremental
vazao_inc=[454.29 340.08 274.84 225.49 221.91 302.87 612.07 1100.59
1462.51...
1376.24 1131.95 746.35 454.29 340.08 274.84 225.49 221.91 302.87 612.07
...
1100.59 1462.51 1376.24 1131.95 746.35;
1879.17 1251.37 1056.35 926.55 808.61 850.13 1285.47 2323.89 3288.37
3621.67...
3731.47 3040.64 1879.17 1251.37 1056.35 926.55 808.61 850.13 1285.47
2323.89...
3288.37 3621.67 3731.47 3040.64;
188.81 64.35 30.39 35.39 29.92 0.00 0.00 0.00 36.24 122.97 295.12
323.48...
188.81 64.35 30.39 35.39 29.92 0.00 0.00 0.00 36.24 122.97 295.12 323.48;
0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00
0.00 ...
0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00;
58.25 22.55 13.61 13.32 12.32 0.00 0.00 0.00 0.00 20.08 49.19 80.21 58.25
...
22.55 13.61 13.32 12.32 0.00 0.00 0.00 0.00 20.08 49.19 80.21;
0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00
0.00...
0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00;
0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00
0.00 ...
0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.00];

%Armazenamentos
arm_ini=zeros(7,25);
arm_ini(1,1)=14180.7;arm_ini(2,1)=24081.85;arm_ini(3,1)=9541.6;
arm_ini(4,1)=128;arm_ini(5,1)=900;arm_ini(6,1)=260;arm_ini(7,1)=3944;
arm_final=zeros(7,24);
arm_medio=zeros(7,24);

%Cotas
cota_mont=zeros(7,24);
cota_jus=zeros(7,24);
alt_liq=zeros(7,24);

%Geração
geracao=zeros(7,24);
horas=[744 720 744 744 720 744 720 744 744 672 744 720 744 720 744 744
...
720 744 720 744 744 672 744 720];
```

```
segs=[2678400 2592000 2678400 2678400 2592000 2678400 2592000 2678400 ...
2678400 2419200 2678400 2592000 2678400 2592000 2678400 2678400 2592000
...
2678400 2592000 2678400 2678400 2419200 2678400 2592000];
```

```
ct_mes=zeros(1,24);
```

```
%Defluências e Vazões
defluencia_p4=0;
vazao_itaparica_mox=0;
defluencia_mox=0;
vazao_turbinada_mox=0;
defluencia_p123=0;
vazao_turbinada_p123=0;
defluencia_xng=0;
vazao_turbinada_xng=0;
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Restrições
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% restrições operativas Três Marias
turb_min_3mar=100;
turb_max_3mar=924;
arm_min_3mar=4250;
arm_max_3mar=19528;
```

```
% restrições operativas Sobradinho
turb_min_sob=640;
turb_max_sob=4278;
arm_min_sob=5447;
arm_max_sob=34116;
```

```
% restrições operativas Itaparica
turb_min_ita=640;
turb_max_ita=3306;
arm_min_ita=7238;
arm_max_ita=10782;
```

```
% restrições operativas Paulo Afonso 4
turb_min_p4=640;
turb_max_p4=2400;
arm_min_p4=128;
arm_max_p4=128;
```

```
% restrições operativas Moxotó
turb_min_mox=640;
turb_max_mox=2090;
arm_min_mox=900;
arm_max_mox=900;
```

```
% restrições operativas Paulo Afonso 123
turb_min_p123=640;
turb_max_p123=2000;
arm_min_p123=260;
arm_max_p123=260;
```

```

% restrições operativas Xingo
turb_min_xng=650;
turb_max_xng=2800;
arm_min_xng=3944;
arm_max_xng=3944;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Simulação do funcionamento das usinas
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%% Usinas de armazenamento
%simulação usina de Três Marias
    for mes=1:24
        arm_final(1,mes)=arm_ini(1,mes)+(vazao_inc(1,mes)-
vazao_defluente(mes))*segs(mes)/1000000;
        arm_med(1,mes)=(arm_ini(1,mes)+arm_final(1,mes))/2;
        cota_mont(1,mes)=530.37+(4.3359e-3*arm_med(1,mes))+(-2.4529e-
7*arm_med(1,mes)^2)+(8.8877e-12*arm_med(1,mes)^3)+(-1.3347e-
16*arm_med(1,mes)^4);
        cota_jus(1,mes)=510.037+(1.92841e-3*vazao_defluente(mes))+(-
1.74094e-7*vazao_defluente(mes)^2)+(1.2127e-11*vazao_defluente(mes)^3)+(-
3.24195e-16*vazao_defluente(mes)^4);
        alt_liq(1,mes)=cota_mont(1,mes)-cota_jus(1,mes);
        arm_ini(1,mes+1)=arm_final(1,mes);
        vazao_turbinada=min([vazao_defluente(mes),turb_max_3mar]);
        geracao1(1,mes)=0.008594*vazao_turbinada*alt_liq(1,mes);
    end;

%simulação usina de SOBRADINHO
    for mes=1:24

arm_final(2,mes)=arm_ini(2,mes)+(vazao_inc(2,mes)+vazao_defluente(mes)-
vazao_defluente(mes+24))*segs(mes)/1000000;
        arm_med(2,mes)=(arm_ini(2,mes)+arm_final(2,mes))/2;
        cota_mont(2,mes)=374.1790+(1.39669e-3*arm_med(2,mes))+(-5.35159e-
8*arm_med(2,mes)^2)+(1.15599e-12*arm_med(2,mes)^3)+(-9.54599e-
18*arm_med(2,mes)^4);
        cota_jus(2,mes)=360.6096+(1.24821e-3*vazao_defluente(mes+24))+(-
1.278032e-7*vazao_defluente(mes+24)^2)+(9.302374e-
12*vazao_defluente(mes+24)^3)+(-2.631139e-16*vazao_defluente(mes+24)^4);
        alt_liq(2,mes)=cota_mont(2,mes)-cota_jus(2,mes);
        arm_ini(2,mes+1)=arm_final(2,mes);
        vazao_turbinada=min([vazao_defluente(mes+24),turb_max_sob]);
        geracao2(2,mes)=0.009025*vazao_turbinada*alt_liq(2,mes);
    end;

%simulação usina de Itaparica
    for mes=1:24

arm_final(3,mes)=arm_ini(3,mes)+(vazao_inc(3,mes)+vazao_defluente(mes+24)
-vazao_defluente(mes+48))*segs(mes)/1000000;
        arm_med(3,mes)=(arm_ini(3,mes)+arm_final(3,mes))/2;
        cota_mont(3,mes)=275.813+(6.76489e-3*arm_med(3,mes))+(-8.86837e-
7*arm_med(3,mes)^2)+(7.06791e-11*arm_med(3,mes)^3)+(-2.23985e-
15*arm_med(3,mes)^4);
        cota_jus(3,mes)=251.5;
        alt_liq(3,mes)=cota_mont(3,mes)-cota_jus(3,mes);
        arm_ini(3,mes+1)=arm_final(3,mes);

```

```

        vazao_turbinada=min([vazao_defluente(mes+48),turb_max_ita]);
        geracao3(3,mes)=0.008927*vazao_turbinada*alt_liq(3,mes);
    end;

%simulação usinas a fio d'água
for mes=1:24

    % Simulação Paulo Afonso 4
    %cálculo da vazão defluente de Itaparica que afluí em Paulo
Afonso 4
    if vazao_defluente(mes+48)>turb_max_p4,
        vazao_itaparica_p4=turb_max_p4;
    else
        vazao_itaparica_p4=vazao_defluente(mes+48);
    end
    defluencia_p4=vazao_inc(4,mes)+vazao_itaparica_p4;
    arm_final(4,mes)=arm_ini(4,mes)-defluencia_p4*segs(mes)/1000000;
    arm_med(4,mes)=(arm_ini(4,mes)+arm_final(4,mes))/2;
    cota_mont(4,mes)=251.5;
    cota_jus(4,mes)=129.044+(2.07974e-3*defluencia_p4)+(-5.27068e-
8*defluencia_p4^2)+(6.66456e-13*defluencia_p4^3)+(-2.23117e-
17*defluencia_p4^4);
    alt_liq(4,mes)=cota_mont(4,mes)-cota_jus(4,mes);
    arm_ini(4,mes+1)=arm_final(4,mes);

    %vazão_turbinada=min([vazão_defluente(mes+24),turb_max_ita]);
    geracao4(4,mes)=0.009035*vazao_itaparica_p4*alt_liq(4,mes);

    % Simulação Moxotó
    %cálculo da vazão defluente de Itaparica que afluí em Moxotó
    vazao_itaparica_mox=vazao_defluente(mes+48)-vazao_itaparica_p4;
    defluencia_mox=vazao_inc(5,mes)+vazao_itaparica_mox;
    arm_final(5,mes)=arm_ini(5,mes)-defluencia_mox*segs(mes)/1000000;
    arm_med(5,mes)=(arm_ini(5,mes)+arm_final(5,mes))/2;
    cota_mont(5,mes)=251.5;
    cota_jus(5,mes)=230.3;
    alt_liq(5,mes)=cota_mont(5,mes)-cota_jus(5,mes);
    arm_ini(5,mes+1)=arm_final(5,mes);
    vazao_turbinada_mox=min([defluencia_mox,turb_max_mox]);
    geracao5(5,mes)=0.009064*vazao_turbinada_mox*alt_liq(5,mes);

    % Simulação Paulo Afonso 123
    defluencia_p123=vazao_inc(6,mes)+defluencia_mox;
    arm_final(6,mes)=arm_ini(6,mes)-
defluencia_p123*segs(mes)/1000000;
    arm_med(6,mes)=(arm_ini(6,mes)+arm_final(6,mes))/2;
    cota_mont(6,mes)=230.3;
    cota_jus(6,mes)=146.10;
    alt_liq(6,mes)=cota_mont(6,mes)-cota_jus(6,mes);
    arm_ini(6,mes+1)=arm_final(6,mes);
    vazao_turbinada_p123=min([defluencia_p123,turb_max_p123]);
    geracao6(6,mes)=0.0088*vazao_turbinada_p123*alt_liq(6,mes);

    % Simulação Xingó
    defluencia_xng=vazao_inc(7,mes)+defluencia_p123+defluencia_p4;
    arm_final(7,mes)=arm_ini(7,mes)-defluencia_xng*segs(mes)/1000000;

```

```

    arm_med(7,mes)=(arm_ini(7,mes)+arm_final(7,mes))/2;
    cota_mont(7,mes)=138;
    cota_jus(7,mes)=17.5;
    alt_liq(7,mes)=cota_mont(7,mes)-cota_jus(7,mes);
    arm_ini(7,mes+1)=arm_final(7,mes);
    vazao_turbinada_xng=min([defluencia_xng,turb_max_xng]);
    geracao7(7,mes)=0.009025*vazao_turbinada_xng*alt_liq(7,mes);
end;

% Cálculo e custo da geração complementar térmica

% cálculo da geração térmica
Gt=(8500-
(geracao1(1,:)+geracao2(2,:)+geracao3(3,:)+geracao4(4,:)+geracao5(5,:)+ge
racao6(6,:)+geracao7(7,:)));
i=find(Gt<0); % identifica as gerações térmicas negativas
Gt(i)=0; % troca as gerações térmicas negativas por zero

% calculo do custo de geração térmica
for t=1:24
    if Gt(t)>=0 & Gt(t)<=638,
        ct_mes(t)=(60*Gt(t))*horas(t);
    end
    if Gt(t)>638 & Gt(t)<=985,
        ct_mes(t)=(66.74*Gt(t)-4291)*horas(t);
    end
    if Gt(t)>985 & Gt(t)<=1136,
        ct_mes(t)=(71.29*Gt(t)-8781.87)*horas(t);
    end
    if Gt(t)>1136 & Gt(t)<=1356,
        ct_mes(t)=(82.72*Gt(t)-21766.35)*horas(t);
    end
    if Gt(t)>1356 & Gt(t)<=1542,
        ct_mes(t)=(87.12*Gt(t)-27732.75)*horas(t);
    end
    if Gt(t)>1542 & Gt(t)<=1889,
        ct_mes(t)=(130.5*Gt(t)-94624.71)*horas(t);
    end
    if Gt(t)>1889,
        ct_mes(t)=(855.31*Gt(t)-1463790.8)*horas(t);
    end
end

% calculo das penalidades por violação de limites de armazenamento
for mes=1:24,

    % violação de armazenamento e defluência de Três Marias
    if arm_final(1,mes)<arm_min_3mar,
        ct_mes(mes)=ct_mes(mes)+(5e8*(arm_final(1,mes)-
arm_min_3mar)^2);
    end
    if arm_final(1,mes)>arm_max_3mar,
        ct_mes(mes)=ct_mes(mes)+(5e8*(arm_final(1,mes)-
arm_max_3mar)^2);
    end
    if vazao_defluente(mes)<turb_min_3mar,

```

```

        ct_mes(mes)=ct_mes(mes)+(5e8*(vazao_defluente(mes)-
turb_min_3mar)^2);
        end

        % violação de armazenamento e defluência de Sobradinho
        if arm_final(2,mes)<arm_min_sob,
            ct_mes(mes)=ct_mes(mes)+(5e8*(arm_final(2,mes)-
arm_min_sob)^2);
        end
        if arm_final(2,mes)>arm_max_sob,
            ct_mes(mes)=ct_mes(mes)+(5e8*(arm_final(2,mes)-
arm_max_sob)^2);
        end
        if vazao_defluente(mes+24)<turb_min_sob,
            ct_mes(mes)=ct_mes(mes)+(5e8*(vazao_defluente(mes+24)-
turb_min_3mar)^2);
        end

        % violação de armazenamento Itaparica
        if arm_final(3,mes)<arm_min_ita,
            ct_mes(mes)=ct_mes(mes)+(5e8*(arm_final(3,mes)-
arm_min_ita)^2);
        end
        if arm_final(3,mes)>arm_max_ita,
            ct_mes(mes)=ct_mes(mes)+(5e8*(arm_final(3,mes)-
arm_max_ita)^2);
        end
        if vazao_defluente(mes+48)<turb_min_ita,
            ct_mes(mes)=ct_mes(mes)+(5e8*(vazao_defluente(mes+48)-
turb_min_ita)^2);
        end

        ct_mes;
    end

% CALCULO DO CUSTO TOTAL DE GERACAO TERMICA
%violação de balanço carga-geração
GT=(8500-
(geracao1(1,:)+geracao2(2,:)+geracao3(3,:)+geracao4(4,:)+geracao5(5,:)+ge
racao6(6,:)+geracao7(7,:)));
if GT>=0
    CT=pvvar([0,ct_mes],0.01);
else
    CT=pvvar([0,ct_mes,100000000],0.01);
end

```