

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
DEPARTAMENTO DE ENGENHARIA DE SISTEMAS

*UM MODELO DE PRÉ-DESPACHO EM
USINAS HIDRELÉTRICAS USANDO
ALGORITMOS GENÉTICOS*

Erinaldo Farias dos Santos

Banca Examinadora:

Takaaki Ohishi (UNICAMP) - Orientador
Adriano A. F. M. Carneiro (USP-S.Carlos)
Fernando José Von Zuben (UNICAMP)
Paulo Morelato França (UNICAMP)

Dissertação submetida à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, para preenchimento dos pré-requisitos parciais para obtenção do Título de Mestre em Engenharia Elétrica.

Outubro de 2001

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

Sa59m Santos, Erinaldo Farias dos
Um modelo de pré-despacho em usinas hidrelétricas
usando algoritmos genéticos / Erinaldo Farias dos
Santos.--Campinas, SP: [s.n.], 2001.

Orientador: Takaaki Ohishi.
Dissertação (mestrado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Elétrica e de
Computação.

1. Sistemas de energia elétrica - controle. 2.
Algoritmos genéticos. 3. Otimização combinatória. 4.
Usinas hidrelétricas. I. Takaaki, Ohishi. II.
Universidade Estadual de Campinas. Faculdade de
Engenharia Elétrica e de Computação. III. Título.

Aos meus pais

Agradecimentos

A Deus, em primeiro lugar, por sempre estar comigo nas horas mais difíceis.

Ao Professor Takaaki Ohishi pela sua grande orientação, apoio e ajuda.

À minha família pelo carinho, apoio e incentivo, apesar da distância.

Às amigas Luciana e Rosângela por todo incentivo, carinho e ajuda.

Aos amigos Makoto, Arce, Adriana e Leonardo pela amizade e convívio.

Aos demais amigos do Cose.

Aos amigos Oderson e Sérgio pela amizade e ajuda na organização deste trabalho.

À CAPES pelo suporte financeiro deste trabalho.

À FAPESP e a Duke Energy International.

E a todos que, de alguma forma, contribuíram para o desenvolvimento deste trabalho.

Resumo

Esta dissertação de Mestrado objetiva o desenvolvimento de uma metodologia para o problema de Pré-Despacho, a qual consiste na determinação de um programa de operação das unidades geradoras de um sistema de energia elétrica para um horizonte de curto prazo. A metodologia foi aplicada a um sistema hidrelétrico e utilizou iterativamente um modelo de Despacho de Máquinas, solucionado através de Algoritmos Genéticos, e um modelo de Despacho de Geração, resolvido com Relaxação Lagrangeana. O Despacho de Máquinas é responsável pela definição dos grupos geradores que estarão em operação em cada intervalo de tempo, tratando-se assim de um problema combinatório, o que justifica o uso de um Algoritmo Genético. Em seguida, depois de definida a configuração de máquinas em operação, o Despacho de Geração soluciona um problema formulado somente com variáveis reais. A função aptidão (*fitness*) do modelo de Algoritmo Genético leva em conta os custos de partida e as perdas nas usinas hidrelétricas. A metodologia foi aplicada a um caso real do Sistema de usinas Hidrelétricas do rio Paranapanema. Para tornar aplicação amigável foi desenvolvido um programa computacional, o qual integra a metodologia de pré-despacho com uma interface em ambiente windows. Essa interface possibilita a definição da quantidade de usinas que devem operar, a configuração do algoritmo de despacho de máquinas, além da visualização de gráficos e tabelas. O programa foi implementado em linguagem de programação C++, usando a plataforma de programação Builder 5.0.

Abstract

This Masters thesis presents a methodology to solve a Hydroelectric Predispach problem. This model take into account the start-up/shutdown costs and constraints of hydroelectric generation units, resulting in a combinatorial problem. The predispach problem was decomposed in two subproblem: a hydro unit commitment subproblem and a optimal dispatch subproblem. The first subproblem determines the start-up and shutdown scheduling of hydro units and Genetic Algorithms was used to solve it. The second subproblem determines the on line generation output and it was treated by Lagrangian Relaxation. The Genetic Algorithm's fitness function is composed of start up and power loss costs in hydroelectric power systems. The methodology was applied to the Paranapanema River Power System. A friendly application software was developed, which was implemented in programming language C++, using Borland Builder 5.0.

Conteúdo

RESUMO.....	V
ABSTRACT	VI
LISTA DE FIGURAS.....	IX
LISTA DE TABELAS.....	XII
ABREVIACÕES E SIMBOLOGIA.....	XIII
CAPÍTULO 1	1
INTRODUÇÃO	1
1.1 DESCRIÇÃO DO PROBLEMA	1
1.2 MOTIVAÇÃO PARA UTILIZAÇÃO DE ALGORITMOS GENÉTICOS	3
1.3 OBJETIVOS DO TRABALHO.....	3
1.4 ORGANIZAÇÃO DO TRABALHO	5
CAPÍTULO 2.....	6
DESPACHO DE MÁQUINAS EM USINAS HIDRELÉTRICAS.....	6
2.1 HORIZONTES DE PLANEJAMENTO DA OPERAÇÃO.....	6
2.2 FUNÇÕES DE PRODUÇÃO DE ENERGIA ELÉTRICA	8
2.3 CÁLCULO DA FUNÇÃO DE PRODUÇÃO	12
2.4 PERDAS NA OPERAÇÃO DE UMA USINA HIDRELÉTRICA	13
2.4.1 Perda por variação no nível do canal de fuga	13
2.4.2 Perda hidráulica.....	14
2.4.3 Perda pela variação do rendimento da turbina	15
2.4.4 Perda Total.....	16
2.5 PARTIDAS E PARADAS DE MÁQUINAS	18
2.6 CURVA DE CARGA DIÁRIA.....	20
2.7 FORMULAÇÃO DO PROBLEMA.....	22
CAPÍTULO 3.....	26
ALGORITMOS GENÉTICOS	26
3.1 COMPUTAÇÃO EVOLUTIVA.....	26
3.2 ALGORITMOS GENÉTICOS	28
3.3 CARACTERÍSTICAS DOS ALGORITMOS GENÉTICOS	30
3.3.1 Codificação de Indivíduos	31
3.3.2 População Inicial de um Algoritmo Genético	32
3.3.3 Função de Adaptabilidade ou Função de Fitness	32
3.3.4 Operadores Genéticos	33
3.3.5 Seleção de Indivíduos para a Próxima Geração.....	36
3.3.6 Parâmetros do Algoritmo Genético.....	39

CAPÍTULO 4.....	41
METODOLOGIA DESENVOLVIDA	41
4.1 PROCEDIMENTO ADOTADO	41
4.2 DESPACHO DE MÁQUINAS	43
4.2.1 Codificação.....	43
4.2.2 População Inicial	44
4.2.3 Recombinação ou Crossover.....	45
4.2.4 Mutação.....	45
4.2.5 População Intermediária.....	46
4.2.6 Seleção.....	46
4.2.7 Função de Adaptabilidade.....	47
4.3 O DESPACHO DE GERAÇÃO	47
4.3.1 Procedimento de resolução	50
CAPÍTULO 5.....	53
ANÁLISE DOS RESULTADOS OBTIDOS.....	53
5.1 ESTUDO DE CASO I	53
5.1.1 Caso sem custos de partida e parada das máquinas.....	54
5.1.2 Caso com custos de partida e parada das máquinas	59
5.1.3 Comparações entre os casos com e sem custos de partida/partida	63
5.2 ESTUDO DE CASO II.....	64
5.2.1 Caso sem custos de partida e parada das máquinas.....	66
5.2.2 Caso com custos de partida e parada das máquinas	69
5.3 INFLUÊNCIA DA POPULAÇÃO INICIAL DO ALGORITMO GENÉTICO	72
5.4 OUTRAS CONSIDERAÇÕES	73
5.5 SOFTWARE DESENVOLVIDO	74
CAPÍTULO 6.....	79
CONCLUSÃO.....	79
REFERÊNCIAS BIBLIOGRÁFICAS	81
ÍNDICE REMISSIVO DE AUTORES.....	87

Lista de Figuras

Figura 1.1- Mapa de Usinas do Rio Paranapanema.....	4
Figura 2.1 – Curva de rendimento de uma turbina hidráulica (Curva Colina).....	11
Figura 2.2 – Curva Colina de turbina do tipo Francis.	15
Figura 2.3 – Curvas de Perdas para 1 máquina.	17
Figura 2.4 – Curvas de Perdas para 2 máquinas.....	18
Figura 2.5 – Curva diária de Carga.....	21
Figura 3.1- Exemplo de Estrutura de um Algoritmo Evolutivo	30
Figura 3.2- <i>Crossover</i> Simples	33
Figura 3.3- <i>Crossover</i> Uniforme	34
Figura 3.4 – Exemplo de <i>Roulette Whell</i>	36
Figura 3.5- Situação antes do ranking (gráfico do <i>fitness</i>).....	37
Figura 3.6 - Situação após o ranking (gráfico do número de ordem).....	38
Figura 4.1- Cromossomo com codificação binária.....	44
Figura 4.2 – Cromossomo com codificação inteira.....	44
Figura 4.3 –Estrutura de resolução do problema (4.2)-(4.5).	51
Figura 5.1– Curva de Carga para o Sistema I.....	54
Figura 5.2 - Curva de Evolução do AG - Melhor Resultado sem Custos de Partida e Parada – Sistema I.....	56
Figura 5.3 – Configuração de Máquinas - Melhor Resultado sem Custos de Partida e Parada - Sistema I.....	56
Figura 5.4 – Curvas de Gerações - Melhor Resultado sem Custos de Partida e Parada - Sistema I	57

Figura 5.5 - Curva de Evolução do AG - 2º Melhor Resultado sem Custos de Partida e Parada – Sistema I	57
Figura 5.6 – Configuração de Máquinas - 2º Melhor Resultado sem Custos de Partida e Parada – Sistema I	58
Figura 5.7 – Curvas de Gerações para o 2º Melhor Resultado sem Custos de Partida e Parada - Sistema I	58
Figura 5.8 - Curvas de Evolução do AG - Melhor Resultado com Custos de Partida e Parada – Sistema I	60
Figura 5.9 - Configuração de Máquinas - Melhor Resultado com Custos de Partida e Parada – Sistema I	60
Figura 5.10 - Curvas de Geração - Melhor Resultado com Custos de Partida e Parada – Sistema I	61
Figura 5.11 - Curva de Evolução do AG – 2º Melhor Resultado com Custos de Partida e Parada – Sistema I	62
Figura 5.12 - Configuração de Máquinas - 2º Melhor Resultado com Custos de Partida e Parada – Sistema I	62
Figura 5.13 - Curvas de Gerações - 2º Melhor Resultado com Custos de Partida e Parada – Sistema I	63
Figura 5.14 – Curva de Carga para o Sistema II	64
Figura 5.15 – Curva de Evolução do AG - Melhor Resultado sem Custos de Partida e Parada - Sistema II.....	67
Figura 5.16 – Curvas de Gerações - Melhor Resultado sem Custos de Partida e Parada - Sistema II.....	67
Figura 5.17 – Configuração de Máquinas - Melhor Resultado sem Custos de Partida e Parada - Sistema II.....	68
Figura 5.18 – Curva de Evolução do AG - Melhor Resultado com Custos de Partida e Parada – Sistema II.....	70

Figura 5.19 – Curvas de Gerações - Melhor Resultado com Custos de Partida e Parada - Sistema II.....	70
Figura 5.20 – Configuração de Máquinas - Melhor Resultado com Custos de Partida e Parada - Sistema II.....	71
Figura 5.21 – Janela Principal	75
Figura 5.22 – Janela de Configuração do Algoritmo Genético	75
Figura 5.23 – Janela da Curva de Carga.....	76
Figura 5.24 – Janela do Desempenho do Algoritmo Genético.....	76
Figura 5.25 – Janela com Tabela de Resultados do Problema	77
Figura 5.26 – Janelas de Configuração de Máquinas	77
Figura 5.27 – Janela de Curvas de Produção de Energia das Usinas	78
Figura 5.28 – Janela com Tabela de Produção de Energia das Usinas.....	78

Lista de Tabelas

Tabela 5.1 – Características das 3 Usinas do Sistema I.....	53
Tabela 5.2 – Configuração do Algoritmo Genético	54
Tabela 5.3 – Resultados das Execuções – Sistema I sem Custos de Partida e Parada	55
Tabela 5.4 – Resultados das Execuções – Sistema I com Custos de Partida e Parada.....	59
Tabela 5.5 – Características das 8 Usinas do Sistema II.....	65
Tabela 5.6 – Resultados das Execuções – Sistema II sem Custos de Partida e Parada.....	66
Tabela 5.7 – Resultados das Execuções - Sistema II com Custos de Partida e Parada.....	69
Tabela 5.8 – Comparação de Tempo Computacional para as Codificações	73

Abreviações e Simbologia

Abreviações

AG: Algoritmos Genéticos

CA: Corrente Alternada

CC: Corrente Contínua

COPEL: Companhia Paranaense de Energia

CTEM: Comitê Técnico para Estudos de Mercado

PC: Personal Computer

RAM: Random Access Memory

Principais Símbolos

MW: Mega Watt

m: metro

m^3/s : metro cúbico por segundo

m/s^2 : metro cúbico por segundo

hm^3 : hectômetro cúbico

kg/m^3 : quilograma por metro cúbico

MHz: Mega Hertz

Mb: Mega Bytes

p: potência gerada na máquina em (*MW*)

g: aceleração da gravidade em (m/s^2)

ρ : peso específico da água em (kg/m^3)

η_{tur} : rendimento da turbina em (%)

η_{ger} : rendimento do gerador em (%)

h_l : altura de queda líquida em (m)

q : volume d'água turbinada por unidade de tempo em (m^3/s)

h_r : cota do nível do reservatório em (m)

h_{cf} : cota do nível do canal de fuga em (m)

h_p : perda hidráulica, expressa em (m)

a_k : coeficientes relativo ao termo de expoente k no polinômio

V : volume de água acumulado no reservatório em (hm^3)

h_r : cota do nível do reservatório em (m)

b_k : coeficientes constantes relativos ao termo de expoente k do polinômio

q_n : vazão turbinada total da usina quando há n máquinas em operação

k : constante característica do conduto forçado em (s^2/m^5)

q : vazão turbinada em (m^3/s) em uma máquina

p_{cfn} : perda em MW , decorrente da elevação do nível do canal de fuga com “ n ” máquinas em operação

q_n : vazão turbinada total com “ n ” máquinas em operação

q_{min} : vazão turbinada mínima com “ n ” máquinas em operação

$h(q_n)$: altura de queda líquida para vazão turbinada q_n

p_{hn} : perda hidráulica em (MW), ocasionada pela operação de “ n ” máquinas

k : constante que expressa as características do conduto forçado

p_{rn} : perda em (MW), associada à variação do rendimento da turbina

η_{tB} : rendimento no ponto B

η_t : rendimento no ponto atual

N : número total de máquinas

T : período de tempo total

P_i^t : potência gerada pela máquina i no tempo t

P_i^{\min} : potência mínima gerada pela máquina i

P_i^{\max} : potência máxima gerada pela máquina i

$F_i[P_i^t]$: função de perdas na máquina i para uma potência gerada P_i^t no tempo t

I_i^t : vetor de estados da máquina i no tempo t

d_t : demanda de carga no tempo t

m_k : meta energética diária da usina k

c_f : custo do MW

c_p : custo partida/parada da máquina i

U : número total de usinas

N_i : número total de máquinas da usina i

n_i^t : número de máquinas ligadas na usina i no tempo t

$P(n_i^t)$: potência gerada pelas n máquinas da usina i no tempo t

$P_{\min}(n_i^t)$: potência mínima gerada por n máquinas da usina i

$P_{\max}(n_i^t)$: potência máxima gerada por n máquinas da usina i

$F_i[P(n_i^t)]$: função de perdas para n máquinas da usina i no tempo t

Capítulo 1

INTRODUÇÃO

1.1 Descrição do Problema

O planejamento da operação de curto prazo (um dia à frente) de sistemas de energia elétrica consiste na determinação de um programa de produção de energia elétrica para o próximo dia, sendo denominado como problema de pré-despacho. Neste processo, é importante escolher adequadamente o número de máquinas (conjunto turbina/gerador) em operação em cada intervalo de tempo, pois esta decisão tem grande influência sobre a eficiência do sistema, e sobre os custos de partida/parada e de manutenção (NILSSON & SJELVGREN,1997b). Sob o ponto de vista de otimização da eficiência do sistema, é interessante variar a configuração das máquinas em operação ao longo do dia, de modo a buscar uma melhor configuração de acordo com a variação da carga. Por outro lado, do ponto de vista dos custos de partida/parada, é melhor variar pouco a configuração das máquinas em operação, em detrimento da eficiência do sistema. Uma análise sob este enfoque foi realizada sobre a operação diária da usina de Itaipu (Brasil), considerando-a isoladamente (ARCE, 1999). Verificou-se que a solução global é uma solução intermediária entre o caso de máxima eficiência e de mínimo custo de partida/parada, porém mais próximo da solução de máxima eficiência, indicando que a otimização da eficiência é mais importante que a minimização dos custos de partida/parada.

O planejamento de curto prazo tem sido assunto de muitos artigos durante as últimas décadas, resultando em uma vasta e diversificada literatura. Modelos de programação matemática constituem os métodos freqüentemente mais adotados para o problema, sendo que são sugeridas diversas técnicas tais como programação dinâmica (CHANG, *et al.*, 1990), o princípio da otimalidade progressiva (AMADO & RIBEIRO, 1987), algoritmos de fluxo de redes (BRANNLUND *et al.*, 1988) e relaxação Lagrangeana (ZHUANG & GALIANA, 1988). Entretanto tais modelos foram aplicados a sistema hidrotérmicos e consideram somente restrições térmicas e hidráulicas simples. Outros trabalhos propuseram uma formulação mais completa, onde foram consideradas as restrições de transmissão que foram representadas através de equações de fluxo de carga CA (LUO *et al.*, 1989) ou CC (OHISHI *et al.*, 1991). Ainda assim, foi observado que nenhum destes trabalhos tinham uma representação detalhada das características da geração hidrelétrica, que é um fator importantíssimo para o planejamento de curto prazo de sistemas hidrelétricos.

SOARES & SALMAZO (1997) desenvolveram um dos primeiros trabalhos em que as características da geração hidrelétricas foram consideradas. Neste trabalho, foi proposto um modelo de pré-despacho que visava minimizar as perdas por geração e transmissão de sistemas hidrotérmicos, o qual foi aplicado ao sistema de potência de responsabilidade da COPEL, localizado na região sul do Brasil. O modelo usava uma combinação heurística e o método Relaxação Lagrangeana.

ARCE (1999) desenvolveu um outro trabalho aplicado a um sistema hidrelétrico, onde as características da geração hidrelétrica foram também consideradas. Neste trabalho foi desenvolvido um modelo de despacho de máquinas incluindo custos de partida e parada usando programação dinâmica, sendo aplicado à Usina de Itaipu.

Neste trabalho o termo pré-despacho refere-se ao processo de elaboração do programa de operação do(s) próximo(s) dia(s). Para obtenção deste programa são importantes duas decisões. A primeira diz respeito à decisão de quais unidades geradoras estarão em operação em todos os intervalos do próximo dia definindo-se tal processo como Despacho de Máquinas. A segunda decisão está relacionada com a determinação do ponto de operação das máquinas em funcionamento ao qual denomina-se como Despacho de Geração.

1.2 Motivação para Utilização de Algoritmos Genéticos

A introdução do número de máquinas como uma variável de decisão complica significativamente o problema de planejamento de curto prazo, pois o problema adquire uma natureza combinatória. A natureza combinatória do problema proporciona um crescimento exponencial do espaço de busca à medida que a quantidade de usinas, número de máquinas e intervalos de discretização aumentam.

Os dois últimos trabalhos referenciados na seção anterior estavam relacionados com o pré-despacho, sendo que para o primeiro trabalho o número de máquinas foi definido através de uma heurística e para o segundo foi usada programação dinâmica.

Uma alternativa para contornar a natureza combinatória do problema pode ser a utilização dos algoritmos genéticos. Nos últimos anos, com o rápido desenvolvimento da teoria evolutiva, este tipo de algoritmo tornou-se uma ferramenta de otimização muito poderosa e de larga aplicação em complexos sistemas de engenharia, incluindo sistemas de potência. Os algoritmos genéticos são técnicas estocásticas de otimização, inspiradas na evolução de sistemas biológicos, usando as metáforas de mecanismos de seleção natural, recombinação genética e sobrevivência dos indivíduos mais aptos.

Os algoritmos genéticos têm sido usados com bastante sucesso na solução de problemas análogos ao trabalho proposto, como por exemplo, o problema de *Unit Commitment* aplicado aos sistemas de potência hidrotérmicos (KAZARLIS, *et al.*, 1996), (MAIFELD & SHEBLE, 1996), (CHENG *et al.*, 2000). Entretanto, neste trabalho, a metodologia desenvolvida é aplicada a sistemas puramente hidrelétricos.

1.3 Objetivos do Trabalho

O objetivo geral deste trabalho é apresentar o desenvolvimento e a aplicação de uma metodologia mista para o tratamento do problema de pré-despacho de usinas hidrelétricas, composto de um modelo baseado em algoritmos genéticos e um modelo de despacho de geração

baseado em Relaxação Lagrangeana. O algoritmo genético é responsável pela escolha da configuração de máquinas em operação, enquanto que o despacho de geração trata do problema de determinar a melhor programação da operação para a configuração de máquinas escolhida pelo algoritmo genético.

A metodologia é aplicada ao Sistema de Usinas Hidrelétricas do rio Paranapanema, localizado na fronteira dos estados de São Paulo e do Paraná (Figura 1.1). Este sistema é composto por oito usinas hidrelétricas, totalizando vinte e nove máquinas e o planejamento é realizado num período de vinte e quatro horas, discretizado em intervalos de uma hora.

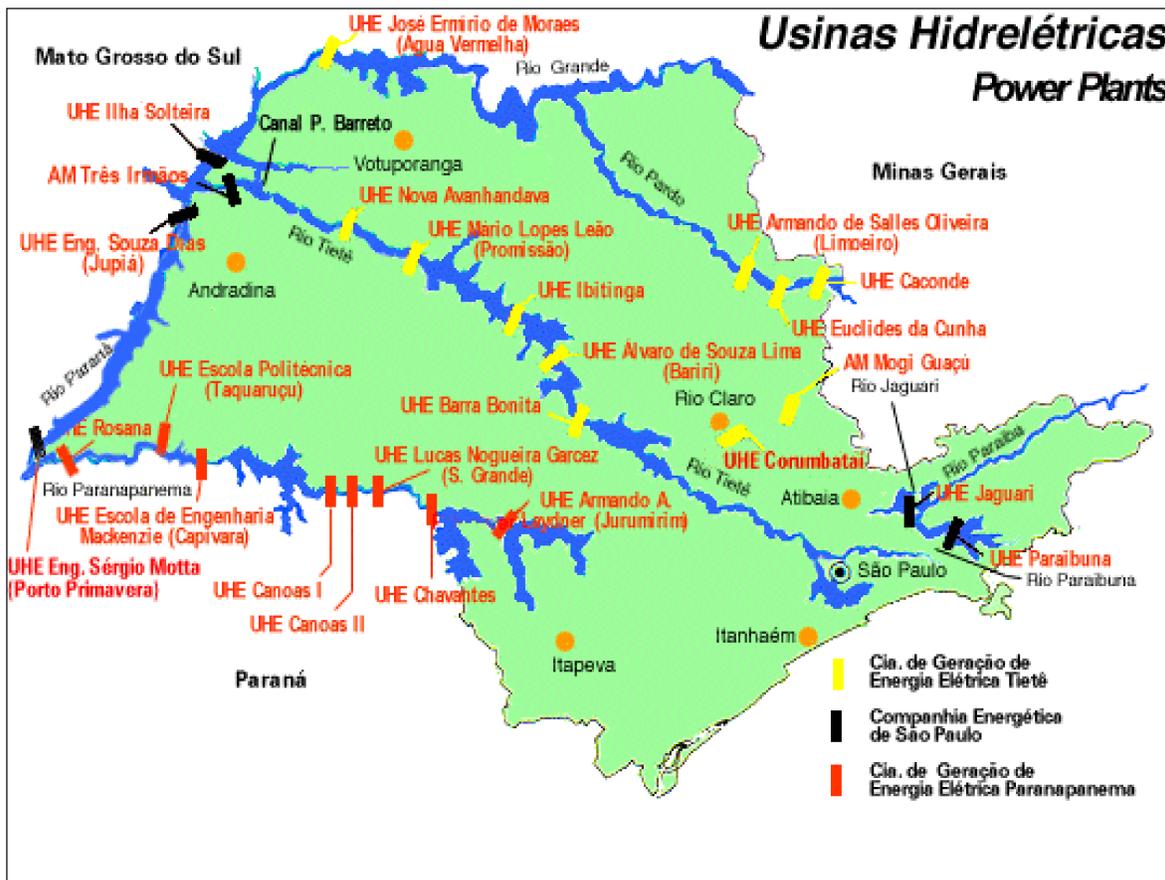


Figura 1.1- Mapa de Usinas do Rio Paranapanema

1.4 Organização do Trabalho

Neste capítulo, foi apresentada uma breve descrição do problema de pré-despacho no planejamento da operação de curto prazo em sistemas de energia elétrica. A ferramenta utilizada para solucionar o problema proposto e os objetivos a serem alcançados com a realização deste trabalho foram também apresentados.

No capítulo 2, é apresentado o despacho de máquinas e sua funcionalidade para a programação da operação de usinas de um sistema de geração de energia elétrica, assim como a formulação do problema proposto neste trabalho. A importância do despacho dentro do planejamento de curto prazo é otimizar a produção de energia através da redução das perdas, além de proporcionar um tempo de vida útil maior para as máquinas que produzem essa energia.

Os algoritmos genéticos são apresentados no capítulo 3. Neste capítulo, são mostrados, de uma forma geral, os principais aspectos de um algoritmo genético, tais como: codificação, operadores, métodos de seleção, etc.

No capítulo 4, é apresentada a metodologia desenvolvida neste trabalho como solução para o problema de pré-despacho e suas particularidades.

A análise dos resultados é apresentada no capítulo 5. Neste capítulo, a metodologia é aplicada para um sistema real, sob dois aspectos: no primeiro é considerado apenas o custo relativo à otimização das perdas, e no segundo, além das perdas são considerados os custos de partida e parada das máquinas.

Finalmente, no capítulo 6, são apresentadas conclusões gerais do trabalho e propostas de pesquisas futuras.

Capítulo 2

DESPACHO DE MÁQUINAS EM USINAS HIDRELÉTRICAS

Neste capítulo, é apresentado o problema de despacho de máquinas e de despacho de geração em usinas hidrelétricas. São descritos, de forma breve, os contextos do despacho e do pré-despacho em uma cadeia de planejamento da operação, os aspectos da produção da energia elétrica, as perdas no sistema de geração, a relação da curva de demanda de carga diária, entrada e saída de máquinas na geração, e finalmente é apresentado um modelo matemático para a representação do problema.

2.1 Horizontes de Planejamento da Operação

O objetivo do planejamento da operação de sistemas de geração de energia elétrica é atender aos requisitos do mercado com confiabilidade e com um custo total mínimo.

Vários aspectos são considerados no planejamento, tais como características hidrológicas do sistema, capacidade de regulação dos reservatórios e acoplamento hidráulico entre usinas hidrelétricas situadas no mesmo rio. Devido a esta diversidade, torna-se necessária uma decomposição em etapas: longo, médio e curto prazo.

No planejamento de longo prazo, deseja-se definir uma estratégia de operação que determine, a cada estágio e em condições incertas de afluências, os totais de energia hidráulica e térmica a serem gerados, de forma a minimizar o valor do custo da operação.

No planejamento da operação de médio prazo, determina-se a política de operação de cada usina, de modo que o custo operacional do sistema ao longo do horizonte seja minimizado, atendendo-se às restrições operativas e aos requisitos do sistema, e que seja compatível com o planejamento de longo prazo. O planejamento da operação de médio prazo determina as metas semanais de operação de cada usina.

Neste trabalho, o alvo principal de atenção é o planejamento da operação de curto prazo, pois tal planejamento procura compatibilizar a operação energética com a operação elétrica do sistema. Devido à sua proximidade da operação em tempo real, o planejamento da operação de curto prazo requer uma representação matemática mais detalhada do sistema, como, por exemplo, a representação da rede elétrica, suas limitações operativas, bem como uma representação detalhada do sistema hidráulico. Neste caso, devido ao curto horizonte do planejamento, supõe-se disponível uma boa previsão de afluência e de demanda de carga, podendo então este problema ser considerado totalmente determinístico (SOARES & OHISHI, 1989).

O atendimento às diretrizes do planejamento de curto prazo e os ajustes às condições atuais do sistema é feito através da programação diária de operação, onde um programa horário de geração define as formas finais de uso das fontes geradoras. Nesta fase do planejamento da operação, são atribuídos os valores de energia que cada usina deverá produzir e a reserva de potência operativa que deverá manter nas próximas 24 horas.

Em seguida à programação diária, tem-se a supervisão da operação que acompanha e corrige as condições operativas do sistema elétrico, tais como o atendimento à carga, a capacidade de produção, capacidade do sistema de transmissão, tendo como objetivo assegurar a continuidade e a qualidade do suprimento, mantendo regulados os níveis de tensão, frequência, etc., que variam instantaneamente.

O fechamento da cadeia de planejamento é estabelecido pela estatística e análise pós-operativa. Nesta etapa, é estabelecida uma visão geral das atividades de gestão de um sistema de produção de energia elétrica, o qual foi iniciado com os estudos de planejamento de geração com

um horizonte de vários anos. O objetivo principal destas atividades é fornecer uma análise do comportamento do sistema e de seus componentes (FORTUNATO *et al.*, 1990).

O despacho de máquinas é de fundamental importância no planejamento da operação, pois através do despacho de cada usina é possível definir a melhor maneira de atender o compromisso assumido na programação diária e efetuar os ajustes com o auxílio da supervisão.

2.2 Funções de Produção de Energia Elétrica

A produção da energia hidroelétrica é o resultado de um processo de transformação da energia potencial da água armazenada no reservatório em energia mecânica através das turbinas. Esta energia mecânica, por sua vez, é transmitida ao gerador através de um eixo, onde, finalmente, grande parte desta energia é transformada em energia elétrica. A energia elétrica gerada passa por uma subestação elevadora de tensão e é injetada no sistema de transmissão para a sua entrega aos centros de consumo (ARCE, 1999).

Partindo da definição de potência como sendo a energia produzida por unidade de tempo, podemos expressar a potência produzida numa máquina de uma usina hidrelétrica através da seguinte relação matemática:

$$p = g \times \rho \times 10^{-6} \times \eta_{tur} \times \eta_{ger} \times h_l \times q \quad (2.1)$$

onde:

p : potência gerada na máquina em (MW);

g : aceleração da gravidade em (m/s^2);

ρ : peso específico da água em (kg/m^3);

η_{tur} : rendimento da turbina em (%);

η_{ger} : rendimento do gerador em (%);

h_l : altura de queda líquida em (m);

q : volume d'água turbinada por unidade de tempo em (m^3/s).

A diferença entre a cota do nível do reservatório e a cota do nível do canal de fuga fornece a altura de queda bruta da usina. Para o cálculo da altura de queda líquida é necessário ainda descontar as perdas hidráulicas, resultando na seguinte expressão:

$$h_l = h_r - h_{cf} - h_p \quad (m) \quad (2.2)$$

onde:

h_r : cota do nível do reservatório em (m);

h_{cf} : cota do nível do canal de fuga em (m);

h_p : perda hidráulica, expressa em (m).

O nível do reservatório $h_r(.)$ é uma função não linear do volume de água armazenado (V) no reservatório. As unidades normalmente adotadas são o metro (m) e o hectômetro cúbico (hm^3) para o nível do reservatório e volume, respectivamente. O nível do reservatório da usina é calculado através da seguinte função polinomial:

$$h_r(V) = a_0 + a_1 \times V + a_2 \times V^2 + a_3 \times V^3 + a_4 \times V^4 \quad (2.3)$$

onde:

a_k : coeficientes relativo ao termo de expoente k no polinômio;

V : volume de água acumulado no reservatório em (hm^3);

h_r : cota do nível do reservatório em (m).

O nível do canal de fuga $h_{cf}(.)$ é uma função não linear da vazão turbinada (q_n) em um dado instante, expresso em m^3/s . O índice n indica que q_n é a vazão total da usina quando n máquinas estão em operação. O nível do canal de fuga da usina em (m), é calculado através da seguinte expressão:

$$h_{cf}(q_n) = b_0 + b_1 \times (q_n) + b_2 \times (q_n)^2 + b_3 \times (q_n)^3 + b_4 \times (q_n)^4 \quad (2.4)$$

onde:

b_k : coeficientes constantes relativos ao termo de expoente k do polinômio;

q_n : vazão turbinada total da usina quando há n máquinas em operação.

A perda hidráulica h_p refere-se à redução da energia potencial pelo atrito da água ao escoar pelo interior do conduto forçado. Para o cálculo da perda são levados em consideração os dados referentes ao comprimento, diâmetro, curvas e rugosidade das paredes internas do conduto forçado. Normalmente, é representado como uma função quadrática do seguinte tipo:

$$h_p = k \times q^2 \quad (2.5)$$

onde:

k : constante característica do conduto forçado em (s^2/m^5) ;

q : vazão turbinada em (m^3/s) em uma máquina.

O rendimento da turbina hidráulica é uma função não linear da vazão turbinada e da altura de queda líquida. Na Figura 2.1, pode-se ver o rendimento de uma turbina hidráulica, que pela sua forma é conhecida como Curva Colina.

Pode-se constatar na Figura 2.1 que, para uma dada altura de queda (h) constante, uma variação da vazão turbinada (q), do seu valor mínimo até seu valor máximo, faz o rendimento variar do seu valor mínimo, passar por um máximo, e chegar a um valor intermediário na turbinagem máxima. Considerando a faixa de operação de uma usina hidrelétrica, há uma grande variação no seu rendimento (em torno de 20%), de modo que é importante escolher adequadamente o seu ponto de operação.

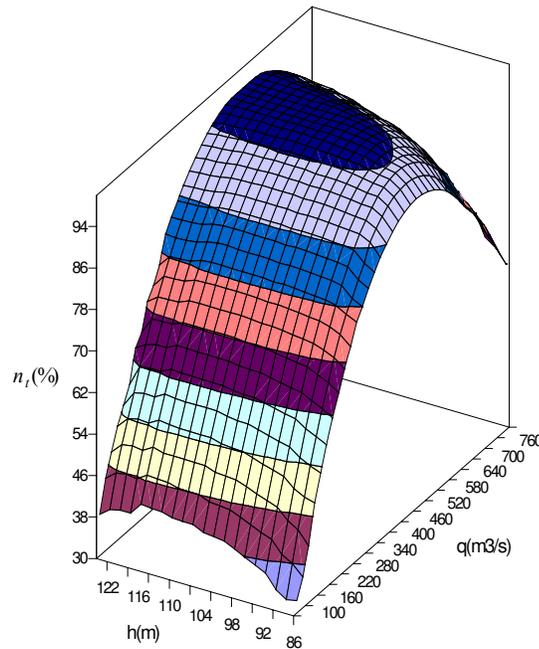


Figura 2.1 – Curva de rendimento de uma turbina hidráulica (Curva Colina).

A transformação da energia mecânica em energia elétrica pelo gerador não é verificada de maneira total, pois nessa transformação também há perdas nos enrolamentos, perdas mecânicas originadas pelo atrito nas escovas do sistema de excitação, perdas no sistema de ventilação e nos mancais. Ainda são verificadas perdas provocadas pela histerese e correntes de Foucault, originadas pela variação da densidade de fluxo magnético no ferro do gerador. Os geradores modernos apresentam rendimentos na faixa de $0.90 \leq \eta_{ger} \leq 0.97$.

Em geral, o uso do rendimento do conjunto turbina-gerador (η_{ig}) é mais freqüente, o qual pode ser definido como o produto entre rendimentos da turbina (η_{tur}) e do gerador (η_{ger}), de acordo com a seguinte equação:

$$\eta_{ig} = \eta_{tur} \times \eta_{ger} \quad (2.6)$$

Neste trabalho, considerou-se o rendimento do gerador constante.

É importante destacar que uma usina hidrelétrica é composta de vários grupos geradores, e que cada grupo gerador possui um conduto forçado. Assim, o nível do reservatório e o nível do

canal de fuga dependem de variáveis de toda a usina. Isto é, o nível do reservatório é função do volume armazenado e o nível do canal de fuga depende da vazão defluente total da usina (soma da vazão turbinada em todos os grupos geradores mais a vazão vertida). Já a perda hidráulica é calculada para cada grupo gerador, pois esta depende da vazão que passa através de cada conduto forçado. O rendimento de cada grupo gerador depende da vazão turbinada e da queda líquida.

2.3 Cálculo da Função de Produção

Através da definição da função de produção, o cálculo da energia produzida por grupo gerador pode ser realizado. Uma metodologia é estabelecida a seguir, de modo que para diferentes configurações de máquinas em operação sejam definidas diferentes funções de produção de energia elétrica. Para o procedimento proposto, supõe-se definida a configuração de grupos geradores em operação e conhecido o volume armazenado no reservatório.

Procedimento:

1. Calcula-se o nível do reservatório através da equação (2.3);
2. Fixa-se a turbinagem no valor mínimo para todos os grupos geradores em operação e calcula-se a vazão turbinada total;
3. Calcula-se o nível do canal de fuga através da equação (2.4);
4. Calcula-se a perda hidráulica em cada grupo gerador através da equação (2.5);
5. Calcula-se a altura de queda líquida através da equação (2.2);
6. Calcula-se o rendimento de cada grupo gerador através da sua curva colina;
7. Calcula-se a potência gerada em cada grupo gerador através da equação (2.1) e, em seguida, calcula-se a potência total gerada na usina;
8. Incrementa-se a vazão turbinada em cada grupo gerador. Se a vazão máxima não é atingida, então, calcula-se a vazão total turbinada e volta-se ao passo 3. Caso contrário, segue-se para o passo 9.

9. Obtém-se a função de produção através de uma aproximação polinomial sobre os valores determinados nos passos anteriores.

2.4 Perdas na Operação de uma Usina Hidrelétrica

Nesta seção, é apresentada uma metodologia usada para o cálculo de funções de perdas na operação de usinas hidrelétricas, sendo consideradas as variações na altura de queda e no rendimento. O objetivo é estimar as perdas na medida em que se varia a produção de energia.

A variação da geração em uma dada usina hidrelétrica ocasiona a variação da vazão turbinada em cada grupo gerador em operação. Dessa forma a variação na turbinagem implica em uma variação no nível do canal de fuga, nos rendimentos e nas perdas hidráulicas. O aumento da turbinagem eleva o nível do canal de fuga, diminuindo assim a altura de queda, o que, por sua vez, diminui a produtividade da usina. Assim, quando se aumenta a turbinagem ocorre um aumento também nas perdas nos condutos forçados.

Nos tópicos a seguir, são apresentadas as equações para cada tipo de perda considerada em uma usina, e depois é estabelecido um procedimento para calcular a perda total. A fim de manter um padrão de comparação comum, estas perdas serão estimadas em termos de perdas de energia (MW).

2.4.1 Perda por variação no nível do canal de fuga

De acordo com a equação (2.4) pode-se observar que o nível do canal de fuga é dado por polinômios de até 4ª ordem em função da vazão defluente.

A avaliação da redução da potência gerada, decorrente da elevação do nível de canal de fuga, pode ser representada através da seguinte expressão:

$$p_{cfn} = (h_l(q_n) - h_l(q_{\min})) \times g \times \rho \times \eta_{tg} \times q_n \times 10^{-6} \quad (2.7)$$

onde:

p_{cfn} : perda em MW , decorrente da elevação do nível do canal de fuga com “ n ” máquinas em operação;

q_n : vazão turbinada total com “ n ” máquinas em operação;

q_{min} : vazão turbinada mínima com “ n ” máquinas em operação;

$h(q_n)$: altura de queda líquida para vazão turbinada q_n .

A máxima altura de queda ocorre para a turbinagem mínima. Quando a vazão turbinada sofre um aumento, ocorre uma elevação do nível do canal de fuga e assim a produtividade da usina diminui. Com isso, pode-se concluir que, do ponto de vista desta perda, é preferível manter a turbinagem em valores baixos, pois assim é obtida uma maior altura de queda.

2.4.2 Perda hidráulica

Através da equação (2.5), verifica-se que a perda hidráulica proporciona uma redução na altura de queda, e dessa forma, proporciona também uma redução na potência gerada, que pode ser quantificada através da seguinte expressão:

$$p_{hn} = (k \times q^2) \times g \times \eta_{ig} \times \rho \times q_n \times 10^{-6} \quad (2.8)$$

onde:

p_{hn} : perda hidráulica em (MW), ocasionada pela operação de “ n ” máquinas;

k : constante que expressa as características do conduto forçado.

De maneira similar à perda por elevação do canal de fuga, avaliada pela equação (2.7), a perda hidráulica também aumenta com o incremento da vazão turbinada, de modo que neste caso é preferível manter a turbinagem em valores baixos, visando ter menos perda hidráulica.

2.4.3 Perda pela variação do rendimento da turbina

A Figura 2.2 mostra uma curva de rendimento para uma turbina do tipo Francis, onde se pode ver que o rendimento, em (%), é definido pela altura de queda líquida, dada em (m), e a vazão turbinada, em (m^3/s), sendo uma representação das curvas de níveis da Figura 2.1. Nesta figura pode ser constatado que, para uma dada cota do reservatório, uma variação da vazão turbinada a partir de um valor mínimo, ponto **A**, até seu valor máximo, ponto **C**, faz o rendimento apresentar um comportamento de crescimento até atingir um valor máximo, ponto **B**, e a partir deste ponto há uma diminuição neste rendimento até que o mesmo alcance o ponto **C**.

Evidentemente, operar no ponto **B** é o ideal, dado que neste ponto obtém-se rendimento máximo do grupo gerador.

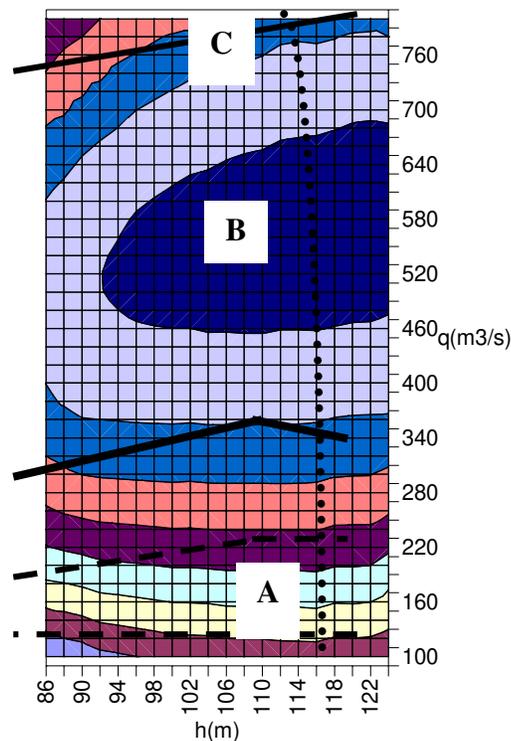


Figura 2.2 – Curva Colina de turbina do tipo Francis.

Para avaliar as perdas associadas à variação do rendimento da turbina, o ponto **B** será considerado como valor de referência ou de “perda nula”. Portanto, o afastamento do ponto de referência ou ponto **B**, será considerado como perda e quantificado pela seguinte expressão:

$$p_m = g \times (\eta_{iB} - \eta_i) \times \rho \times q_n \times h_l \times 10^{-6} \quad (2.9)$$

onde:

p_m : perda em (MW), associada à variação do rendimento da turbina.

η_{iB} : rendimento no ponto B.

η_i : rendimento no ponto atual.

A equação (2.9) avalia a perda em (MW) dos grupos geradores em operação na usina quando estes trabalham em um ponto de menor rendimento (η_i). Comparando com as duas perdas avaliadas pelas equações (2.7) e (2.8), pode-se observar que o comportamento das perdas por rendimento é diferente, pois esta última incentiva o grupo gerador a operar em torno do ponto B, localizado em geral mais próximo do ponto de máxima geração. Enquanto que, do ponto de vista das perdas no canal de fuga e hidráulica, o ideal é operar próximo do limite inferior.

2.4.4 Perda Total

Considerando a metodologia para o cálculo dos diferentes componentes da perda na operação de uma usina hidrelétrica vista nos tópicos anteriores, e supondo conhecido o volume do reservatório, a avaliação do total de perdas para um dado número de máquinas em operação pode finalmente ser realizada. Esta avaliação é feita através do seguinte procedimento:

1. Dado um volume armazenado, calcula-se a cota do reservatório através da equação (2.3);
2. Inicializa-se a vazão turbinada de cada grupo gerador em seu valor mínimo e calcula-se a vazão total turbinada;
3. Calcula-se o valor do nível de canal de fuga através da equação (2.4);
4. Calcula-se a perda hidráulica através da equação (2.5);

5. Calcula-se a altura de queda líquida através da equação (2.2);
6. Calcula-se o rendimento através da curva colina;
7. Calcula-se as perdas de rendimento através da equação (2.9), as perdas no nível do canal de fuga através da equação (2.7) e as perdas hidráulicas através da equação (2.8). Soma-se estas três perdas obtendo a perda total para esta turbinagem (ou potência gerada);
8. Incrementa-se a vazão turbinada. Se esta ultrapassar a turbinagem máxima, então vá para o passo 9. Caso contrário calcula-se a vazão turbinada total e volta-se para o passo 3;
9. Obtém-se a função de perdas através de uma aproximação polinomial dos pontos calculados nos passos acima.

Nas figuras a seguir são apresentadas curvas de perdas para a usina de Jurumirim, situada no rio Paranapanema. Através destas curvas, foram calculadas as perdas para 1 máquina (Figura 2.3) e 2 máquinas (Figura 2.4) em operação na referida usina.

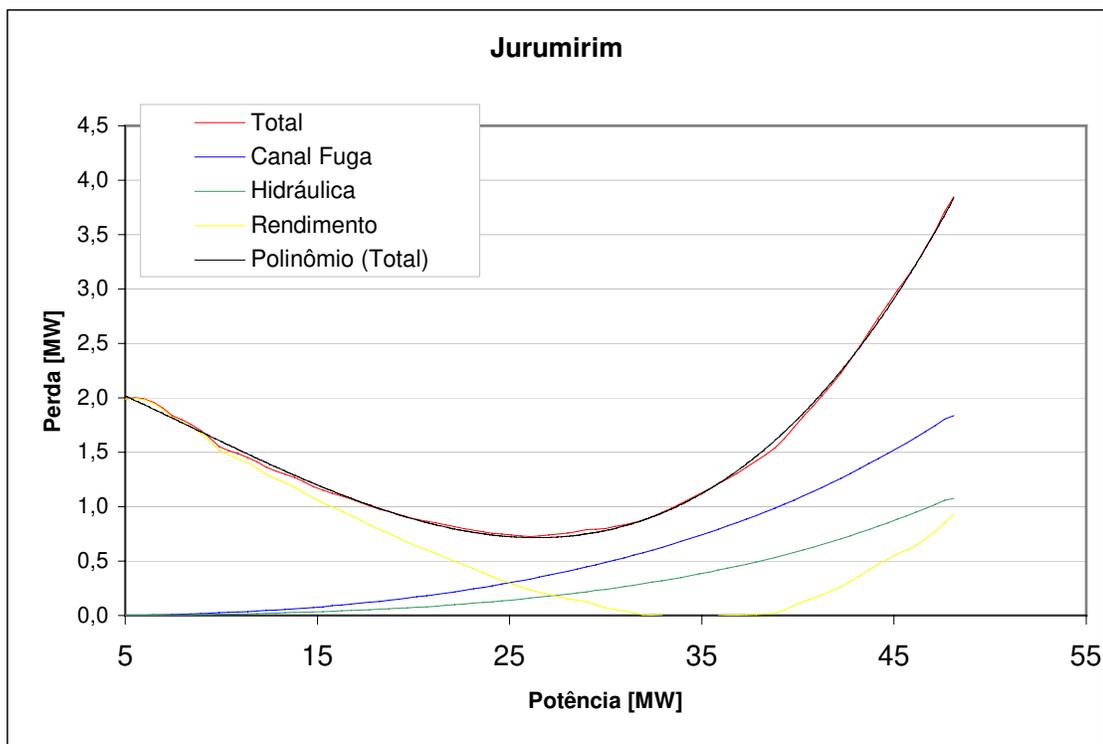


Figura 2.3 – Curvas de Perdas para 1 máquina.

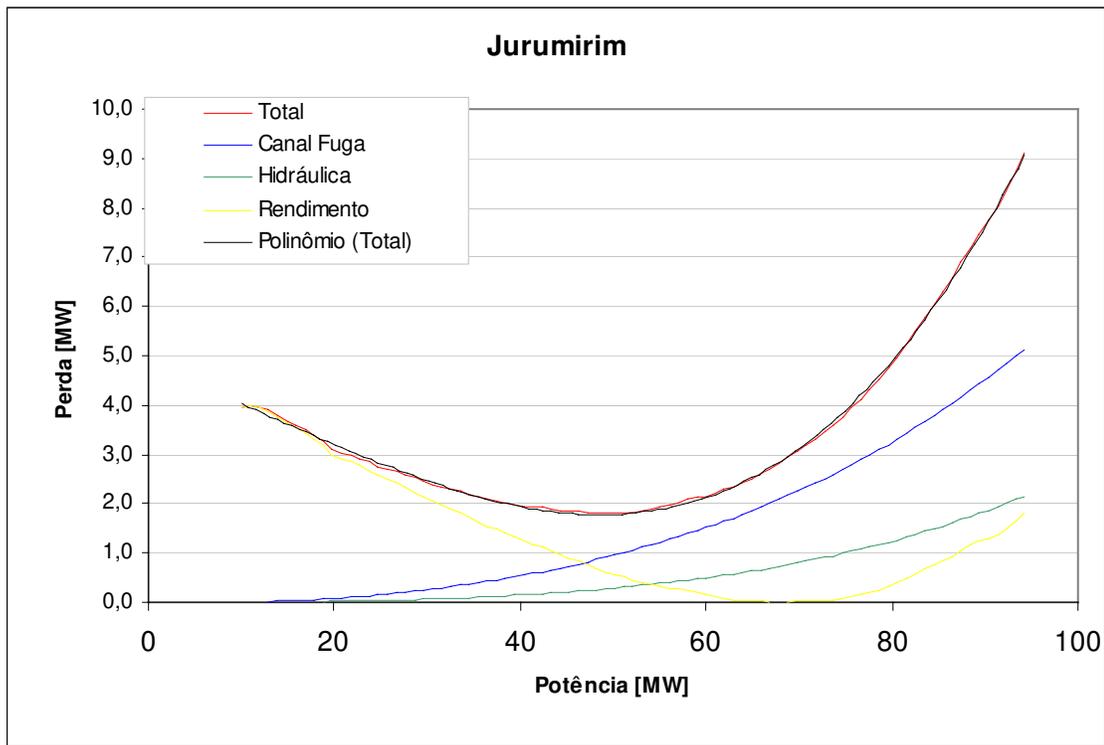


Figura 2.4 – Curvas de Perdas para 2 máquinas.

2.5 Partidas e Paradas de Máquinas

Um dos principais objetivos no processo de despacho de máquinas está relacionado com a minimização de perdas no sistema de geração. Porém, existe também a necessidade de se quantificar o custo associado às partidas e paradas das unidades hidráulicas, devido ao aspecto desta operação envolver custos relacionados com a manutenção e redução da vida útil das unidades geradoras.

Na literatura, existem poucos trabalhos tratando da questão de partidas/paradas de máquinas hidráulicas. A grande maioria trata apenas de partidas/paradas de unidades térmicas. O motivo da preferência pelo problema térmico está provavelmente associado ao fato de que a maioria dos sistemas de energia elétrica no mundo seja de predominância termoelétrica e também porque os custos de partida/parada são menos óbvios para unidades hidráulicas do que para

unidades térmicas. Porém, os estudos têm mostrado que os custos de partida/parada de unidades hidráulicas são significativos e merecem estudos mais detalhados.

Alguns estudos relacionados com despacho de máquinas tentaram explorar e quantificar o custo associado às partidas das unidades hidráulicas, dentre estes, podemos citar os seguintes:

- 1) NILSSON & SJELVGREN (1997a) publicaram um trabalho, onde depois de entrevistarem os maiores produtores de energia da Suécia, buscaram estimar fatores que ocasionam custos e chegaram a definir um custo de partida aproximado de 3 dólares por *MW* instalado.
- 2) HARA *et al.* (1995), publicaram um trabalho onde são apresentados os principais fatores que contribuem para a degradação do sistema de isolamento dos geradores e a diminuição da sua vida útil, e em seguida avaliam os custos relacionados ao regime de operação das máquinas da usina hidrelétrica de G. B. Munhoz, da COPEL. Os custos de partidas e paradas foram obtidos através de equações que medem a degradação da vida útil do isolamento do gerador para diferentes níveis de tensão residual e número de partidas e paradas. Por este método de avaliação concluíram que a operação de 37 anos contendo uma partida/parada por dia resulta na redução de 10 anos na sua vida útil.
- 3) NILSSON & SJELVGREN (1997b) apresentaram um modelo para otimização do programa de geração de um sistema eminentemente hidráulico, com a possibilidade de comprar e vender energia de/para um sistema vizinho. Para a solução, foi adotada a técnica de decomposição, transformando o problema em subproblemas para cada usina hidráulica, através da relaxação de algumas restrições. O custo adotado para cada partida foi o mesmo considerado no estudo anterior, realizado pelos mesmos autores, onde foi considerado 3 dólares/*MW* vezes a potência nominal da máquina.
- 4) ARCE (1999) desenvolveu uma dissertação de Mestrado na qual implementou um modelo de pré-despacho para a usina de Itaipu, considerando partidas e paradas de máquinas. Neste trabalho, foram feitas análises da influência dos custos de partida e parada sobre a solução do pré-despacho. As mais importantes foram: 1) conclusões de que a otimização da produtividade (minimização das perdas) é um aspecto mais

importante que os custos de partida; 2) é possível reduzir os custos de partidas significativamente sem grandes perdas na produtividade. A metodologia utilizada neste caso foi a programação dinâmica, sendo considerado o mesmo custo de partida estimado por NILSSON & SJELVGREN (1997b).

Os estudos referidos anteriormente apontam os principais aspectos relacionados com os custos de partidas e paradas de máquinas, dentre os quais pode-se citar:

- a. Degradação do sistema de isolamento dos enrolamentos do gerador, devido às mudanças de temperatura verificadas durante as partidas e paradas.
- b. Desgastes dos equipamentos mecânicos, ocasionando aumento dos serviços e custos de manutenção dos mesmos.
- c. Falha nos equipamentos de controle durante as partidas e paradas, que ocasionam custos associados ao concerto de falhas e a energia que deixa de ser gerada durante a indisponibilidade da máquina.

A variação da curva de carga ou da geração programada ao longo do dia proporciona um freqüente acionamento e desligamento de máquinas no sentido de manter o equilíbrio entre a carga e a geração, de modo que são inevitáveis as partidas e paradas ao longo do dia. A questão, portanto, é como otimizar estas entradas e saídas de unidades hidráulicas.

2.6 Curva de Carga Diária

O problema de despacho de geração possui uma restrição vinculada à curva de carga diária, ou seja, as usinas devem operar com uma certa quantidade de máquinas de forma a atender à demanda de carga solicitada pelo sistema. A Figura 2.5 mostra a curva de carga diária típica do estado de São Paulo, com discretização horária.

A curva de carga apresenta um comportamento bastante variável ao longo do dia, o que indica que em certos intervalos de tempo as usinas devem aumentar o número de máquinas e em outros reduzir, de forma a deixar as máquinas operando em pontos bem próximos do ótimo.

Além disso, o número de máquinas em operação em cada intervalo deve ser determinado de forma que o montante de energia exigida pelo sistema durante o dia não ultrapasse a meta diária de cada usina.

Pode-se notar que deve existir um compromisso em atender a demanda a cada intervalo e a meta diária de cada usina, o que complica bastante o problema de despacho de geração.

A curva de carga exerce um papel importante para criação de população inicial de configurações de máquinas para o algoritmo genético (Veja Seção 4.2.2), diminuindo o número de configurações infactíveis, as quais certamente são encontradas a partir de uma escolha totalmente aleatória.

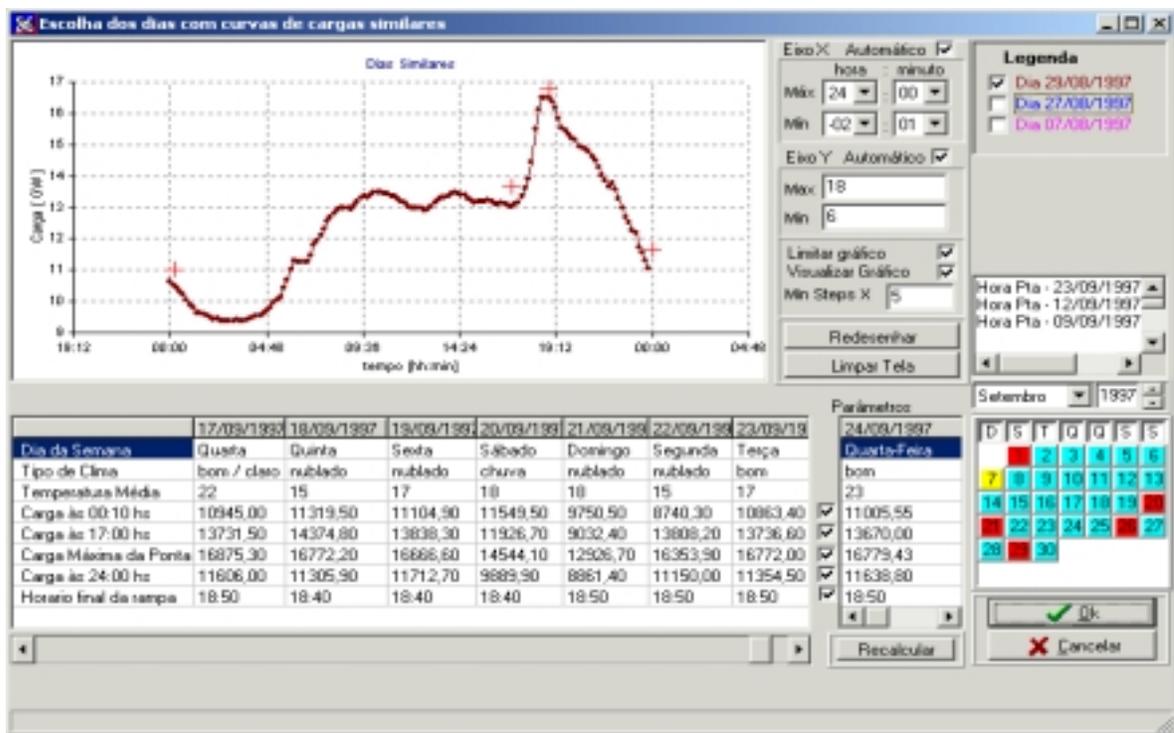


Figura 2.5 – Curva diária de Carga

2.7 Formulação do Problema

O problema da determinação do número de máquinas que devem operar em cada usina no sistema hidrelétrico, em cada intervalo de tempo, de forma a minimizar as perdas de energia, sujeito a restrições de atendimento das demandas, metas diárias e limites de geração de potência das turbinas, pode ser colocado da seguinte forma:

$$\min_{I, P} \sum_{t=1}^T \sum_{i=1}^N c_f \cdot F_i[P_i^t] \cdot I_i^t + c_{P_i} |I_i^t - I_i^{t-1}| \quad (2.10)$$

sujeito a:

$$\sum_{i=1}^N P_i^t \cdot I_i^t \geq d_t \quad t = 1, \dots, T. \quad (2.11)$$

$$\sum_{i \in Q_k} \sum_{t=1}^T P_i^t \cdot I_i^t = m_k \quad k = 1, \dots, U. \quad (2.12)$$

$$P_i^{\min} \cdot I_i^t \leq P_i^t \leq P_i^{\max} \cdot I_i^t \quad \begin{cases} i = 1, \dots, N; \\ t = 1, \dots, T. \end{cases} \quad (2.13)$$

$$I_i^t \in \{0,1\} \quad \begin{cases} i = 1, \dots, N; \\ t = 1, \dots, T. \end{cases} \quad (2.14)$$

$$I_i^{t=0} - \text{dado}. \quad (2.15)$$

onde:

N : número total de máquinas.

T : período de tempo total;

P_i^t : potência gerada pela máquina i no tempo t ;

P_i^{\min} : potência mínima gerada pela máquina i ;

P_i^{\max} : potência máxima gerada pela máquina i ;

$F_i[P_i^t]$: função de perdas na máquina i para uma potência gerada P_i^t no tempo t ;

I_i^t : vetor de estados da máquina i no tempo t (1=ligado, 0=desligado);

d_t : demanda de carga no tempo t ;

m_k : meta energética diária da usina k ;

c_f : custo do MW ;

c_p : custo partida/parada da máquina i ;

A função objetivo (2.10) representa o custo total (custos das perdas mais custos de partidas) ao longo do dia; a restrição (2.11) assegura o atendimento da demanda total em cada intervalo de tempo; a equação (2.12) refere-se ao atendimento das metas energéticas, sendo que estas metas energéticas são definidas nos planejamentos de médio e longo prazos e estabelecem a cota de produção diária para cada usina hidrelétrica; a restrição (2.13) representa os limites operativos das máquinas e as restrições (2.14) e (2.15) se referem às variáveis binárias.

O problema (2.10) - (2.15) é de natureza combinatória ($2^{N \times T}$ soluções possíveis), o que torna impossível a enumeração de todas as soluções com os computadores atuais para N e/ou T grande(s). Este problema pode ser classificado como um problema misto, já que também é decidida a potência gerada em cada usina, a qual é representada por uma variável contínua. É importante destacar que, na formulação acima, cada unidade (máquina) é individualmente representada. Em termos do jargão da área, este problema corresponde a um problema de “*Unit Commitment*” hidráulico.

O *Unit Commitment* é um problema tradicional, porém geralmente utilizados em sistemas com predominância termoeletrica. Este problema possui uma alta complexidade matemática, e a solução exata para sistemas de potências reais de porte requer um excessivo tempo computacional. Para contornar essa dificuldade, a literatura apresenta diversos métodos que foram desenvolvidos para encontrar soluções próximas do ótimo para o referido problema de

“Unit Commitment”, tais como, lista de prioridade, programação dinâmica, relaxação Lagrangeana, *branch and bound*, decomposição Benders, etc (SHEBLE & FAHD, 1994).

Uma segunda formulação é sugerida quando se trabalha com usinas que possuem todas as máquinas iguais, e quando a preocupação é apenas definir a quantidade de máquinas que deverão operar:

$$\min_{n,P} \sum_{t=1}^T \sum_{i=1}^U c_f \cdot F_i[P(n_i^t)] + c_{Pi} \cdot |n_i^t - n_i^{t-1}| \quad (2.16)$$

$$\sum_{i=1}^U P(n_i^t) \geq d_t \quad t = 1, \dots, T. \quad (2.17)$$

$$\sum_{t=1}^T P(n_i^t) = m_i \quad i = 1, \dots, U. \quad (2.18)$$

$$P_{\min}(n_i^t) \leq P(n_i^t) \leq P_{\max}(n_i^t) \quad \begin{cases} t = 1, \dots, T; \\ i = 1, \dots, U. \end{cases} \quad (2.19)$$

$$1 \leq n_i^t \leq N_i \quad \begin{cases} t = 1, \dots, T; \\ i = 1, \dots, U. \end{cases} \quad (2.20)$$

$$n_i^{t=0} - \text{dado}. \quad (2.21)$$

onde:

U : número total de usinas.

T : período de tempo total;

N_i : número total de máquinas da usina i ;

n_i^t : número de máquinas ligadas na usina i no tempo t ;

$P(n_i^t)$: potência gerada pelas n máquinas da usina i no tempo t ;

- $P_{\min}(n_i^t)$: potência mínima gerada por n máquinas da usina i ;
- $P_{\max}(n_i^t)$: potência máxima gerada por n máquinas da usina i ;
- $F_i[P(n_i^t)]$: função de perdas para n máquinas da usina i no tempo t ;
- d_t : demanda de carga no tempo t ;
- m_k : meta energética diária da usina k ;
- c_f : custo do MW ;
- c_{Pi} : custo partida/parada.

Com a formulação (2.16) - (2.21), o espaço de busca tem uma redução significativa. Porém tal redução ainda não é suficiente para fazer uma enumeração de todas as soluções. O tamanho do espaço de busca é definido através da seguinte expressão:

$$\left(\prod_{i=1}^U N_i \right)^T \quad (2.22)$$

A metodologia desenvolvida para resolver os problemas formulados anteriormente é baseada em algoritmos genéticos e Relaxação Lagrangeana. O algoritmo genético é responsável pela resolução da parte inteira do problema, ou seja, definição do número de máquinas em operação. A Relaxação Lagrangeana é responsável pela resolução da parte real (variáveis contínuas) do problema, ou seja, definição do ponto de operação das máquinas em funcionamento. Mais detalhes da metodologia podem ser vistos no capítulo 4.

Capítulo 3

ALGORITMOS GENÉTICOS

As simples comparações de desempenho de dispositivos naturais e artificiais ativaram o interesse humano pelo desenvolvimento de processos de imitação da natureza, e de certa forma esse interesse proporcionou o surgimento de técnicas capazes de reproduzir sistemas computacionais inspirados na natureza, englobando a inteligência computacional, vida artificial, sistemas complexos e geometria fractal. Dentro do contexto da Inteligência Computacional, está a computação evolutiva e outros métodos que merecem destaque, como sistemas *fuzzy*, redes neurais artificiais e agentes autônomos.

Neste capítulo, inicialmente são descritas sucintamente a computação evolutiva e as principais abordagens encontradas na literatura relacionadas com esta técnica. A seguir, um destaque maior é dado aos algoritmos genéticos, devido ao fato do mesmo fazer parte da metodologia desenvolvida neste trabalho. Uma revisão e formalização de conceitos da computação evolutiva, necessários para um aprofundamento maior no assunto, podem ser encontrados em IYODA (2000).

3.1 Computação Evolutiva

Evolução é com certeza o princípio unificador da biologia moderna. A computação evolutiva é o termo padrão que incorpora os algoritmos inspirados na teoria de evolução natural

de Darwin, podendo estes algoritmos ser utilizados como ferramentas adaptativas para solução de problemas e como modelos computacionais de processos evolutivos naturais.

É de fundamental importância destacar que as técnicas baseadas na computação evolutiva devem ser empregadas quando não existem abordagens clássicas ou específicas, ou quando estas não são aplicáveis ou falham quando utilizadas para solucionar algum problema. Portanto, as abordagens envolvendo computação evolutiva não devem ser empregadas como ponto de partida para a busca da solução de um problema, seja qual for este problema.

As técnicas baseadas em computação evolutiva compõem um conjunto de algoritmos que apresentam muitas similaridades tais como: manutenção de uma população de soluções que são evoluídas através de alterações aleatórias e seleção. Porém existem algumas diferenças nas técnicas de codificação dos candidatos, nos tipos de alterações usadas para criar novas soluções, e no mecanismo empregado para selecionar novos pais. Existem três linhas principais de pesquisa no campo da computação evolutiva:

- Algoritmos genéticos;
- Estratégias evolutivas;
- Programação evolutiva.

Os algoritmos genéticos foram concebidos por J. Holland (HOLLAND, 1992) com a finalidade de importar a evolução natural para dentro de sistemas computacionais. Estes algoritmos empregam operadores inspirados na genética, tais como *crossover* e mutação, além dos processos de seleção. Os algoritmos genéticos, nos últimos anos, têm sido amplamente aplicados para solucionar diversos problemas de otimização, embora tenham sido desenvolvidos inicialmente com um propósito totalmente diferente.

FOGEL (1995) afirma que evolução pode ser categorizada por vários níveis hierárquicos: o gene, o cromossomo, o indivíduo, as espécies, e o ecossistema. Assim, enquanto os algoritmos genéticos enfatizam modelos de operadores genéticos, as estratégias evolutivas priorizam transformações mutacionais que mantêm elo de ligação entre cada pai e seu descendente. Estratégias evolutivas (RECHENBERG, 1973), (SCHWEFEL, 1995) foram inicialmente desenvolvidas com o propósito de solucionar problemas de otimização de parâmetros, tanto

discretos como contínuos. Diversas implementações e desenvolvimentos mais recentes empregando estratégias evolutivas podem ser encontrados em (BÄCK, 1996).

Os primeiros trabalhos envolvendo programação evolutiva foram desenvolvidos por FOGEL *et al.* (1966). A programação evolutiva foi originalmente aplicada como uma técnica capaz de produzir inteligência artificial pela evolução de máquinas de estado finito. Nos últimos anos, a programação evolutiva foi empregada a vários problemas de otimização, sendo aplicada, neste caso, de forma análoga às estratégias evolutivas.

3.2 Algoritmos Genéticos

Os algoritmos genéticos são algoritmos de busca estocástica, combinando sobrevivência artificial através do princípio da adaptabilidade com operadores genéticos abstraídos dos sistemas biológicos. Eles formam um mecanismo surpreendentemente robusto e muito eficiente para encontrar soluções otimizadas para problemas complexos do mundo real. Os algoritmos genéticos são aplicados com sucesso em várias áreas, tais como geração de música, estratégias de planejamento, aprendizado em máquinas, etc.

Os algoritmos genéticos foram introduzidos em meados de 1976 por HOLLAND (1992) e seus colaboradores da Universidade de Michigan. Contudo, o seu pleno desenvolvimento só ocorreu a partir da última década. Embora recente, tais técnicas têm alcançado enorme sucesso na solução de problemas de elevada complexidade.

A terminologia utilizada no desenvolvimento dos algoritmos genéticos foi baseada na teoria da evolução natural e da genética. Inicialmente, é proposta uma população de indivíduos, e cada indivíduo é representado por um cromossomo que possui uma codificação (genótipo) de uma suposta solução do problema (fenótipo). De uma forma geral, os cromossomos são implementados através de vetores ou listas de atributos, onde cada componente do vetor ou atributo representa um gene. Os genes, por sua vez, podem assumir diversos valores de acordo com o tipo de codificação e estes valores recebem a denominação de alelos.

Todo o processo de evolução embutido em um algoritmo genético funciona como um processo capaz de percorrer um espaço de busca de soluções potenciais para um determinado problema. Segundo MICHALEWICZ (1996), para percorrer este espaço de busca é necessário manter um equilíbrio entre dois pontos contrastantes:

- Exploração: que consiste no aproveitamento das melhores soluções e;
- Exploração: que consiste na exploração do espaço de busca.

Pode-se observar que existe uma dificuldade muito grande para que este equilíbrio seja alcançado quando, aos mesmos problemas, forem aplicadas outras técnicas de busca. Os métodos de otimização clássicos, como o método do gradiente, são métodos que consideram somente a melhor solução na busca de possíveis melhorias, não realizando uma exploração efetiva do espaço de busca. Considerando os métodos de busca aleatória, nota-se que os mesmos pertencem a uma classe de métodos que enfatizam a exploração do espaço de busca, porém ignoram o aproveitamento de regiões promissoras do espaço considerado.

Diversos estudos comprovaram que os algoritmos genéticos mantêm um equilíbrio notável nos pontos de contraste apresentados anteriormente e, portanto, conseguem fazer o aproveitamento de melhores soluções e exploração do espaço de busca. Embora sejam identificadas etapas não-determinísticas em seu desenvolvimento, os algoritmos genéticos não são métodos de busca totalmente aleatórios, e sim métodos que relacionam variações aleatórias com seleção polarizada pelos valores de adequação (*fitness*) atribuídos a cada indivíduo (IYODA, 2000).

A multi-direcionalidade é uma outra importante propriedade atribuída aos algoritmos genéticos, pelo fato dos mesmos manterem uma população de soluções candidatas, proporcionando assim uma constante troca de informação entre diversas direções de busca. A cada geração do algoritmo genético, soluções relativamente "boas" se reproduzem, enquanto que soluções relativamente "ruins" são eliminadas. Para fazer a distinção entre diferentes soluções, é empregada uma função de avaliação ou de adaptabilidade (*fitness*) que simula o papel da pressão exercida pelo ambiente sobre o indivíduo. Esta estratégia populacional, entretanto, não é verificada em outros métodos alternativos, como *simulated annealing* (AARTS & KORST, 1989) e busca tabu (GLOVER, 1990), que processam um único ponto no espaço de busca a cada instante.

A estrutura de um algoritmo genético e de outros algoritmos evolutivos é idêntica, apesar das abordagens terem sido desenvolvidas de forma independente. A Figura 3.1 a seguir apresenta a referida estrutura (MICHALEWICZ, 1996):

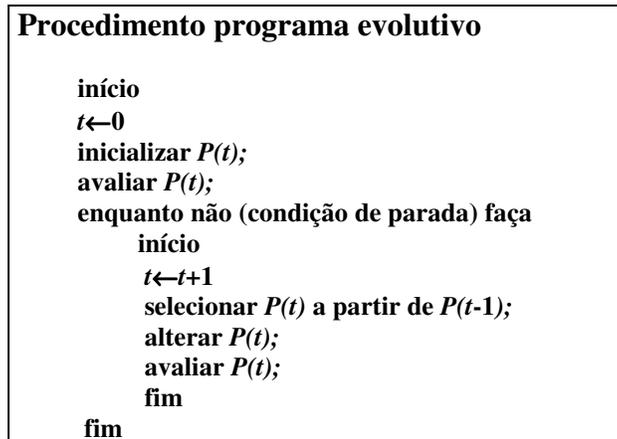


Figura 3.1- Exemplo de Estrutura de um Algoritmo Evolutivo

De acordo com esta estrutura, um algoritmo genético pode ser descrito da seguinte maneira: durante a iteração t , uma população $P(t) = \{y_1^t, \dots, y_n^t\}$, contendo as soluções potenciais e representadas por cromossomos, vetores ou listas, é mantida. Em seguida, cada solução passa por um processo de avaliação, produzindo-se uma medida de adaptação ou *fitness* para cada uma. Uma nova população (iteração $t + 1$) é então produzida através de uma seleção que privilegia os indivíduos mais adaptados. Alguns indivíduos da nova população sofrem alterações, por meio de recombinação ou *crossover* e mutação, para formar novas soluções potenciais. Esse processo é então repetido até que um número predefinido de iterações seja atingido ou até que o nível de adaptação esperado seja obtido.

3.3 Características dos Algoritmos Genéticos

Os algoritmos genéticos implementados para a maioria dos problemas nos quais são aplicados, devem ter os seguintes componentes:

- escolha de uma representação genética para soluções candidatas ou potenciais, ou seja, processo de codificação;
- uma forma de gerar uma população inicial de soluções candidatas ou potenciais;
- uma função de adaptabilidade que corresponde à pressão ambiental, tendo a função de avaliar as soluções e classificá-las de acordo com sua adaptação ao meio;
- operadores genéticos;
- identificar os valores para os vários parâmetros usados pelo algoritmo genético tais como: tamanho da população, probabilidades de aplicação dos operadores genéticos, número de gerações, etc.

A seguir, uma descrição mais detalhada das partes constituintes de um algoritmo genético é apresentada.

3.3.1 Codificação de Indivíduos

A codificação é uma das etapas mais críticas na definição de um algoritmo genético, por isso deve ser um dos primeiros aspectos a serem considerados durante a fase de implementação. No algoritmo genético clássico, proposto por HOLLAND (1992), a codificação das soluções candidatas é estabelecida através de arranjos binários de tamanho fixo. A principal motivação para o uso deste tipo de codificação vem da teoria de esquemas (*schemata theory*), que explica com relativo sucesso a forma de funcionamento dos algoritmos genéticos.

Entretanto, em diversos problemas práticos a codificação binária não apresenta um desempenho satisfatório. MICHALEWICZ (1996) argumenta que a representação binária tem desempenho pobre em problemas numéricos de alta dimensionalidade e onde uma alta precisão é requerida.

Os algoritmos genéticos podem ser construídos com uma codificação que representa um valor real ou inteiro para as variáveis. No caso da codificação real, normalmente a solução de um problema está associada a um cromossomo p representado na forma de um vetor ou uma lista no

$\mathfrak{R}^n : p = (x_1, x_2, \dots, x_n)$, onde cada x_i representa uma variável de valor real que caracteriza a solução do problema.

Uma vantagem da codificação real é o fato de, em geral, ser mais intuitivo conceber operadores de recombinação (*crossover*) e de mutação para um dado problema lançando mão de conhecimento já previamente adquirido no domínio da aplicação.

3.3.2 População Inicial de um Algoritmo Genético

A população de um algoritmo genético é um conjunto de possíveis soluções para um determinado problema. Cada indivíduo na população é representado por um cromossomo composto por uma seqüência de números, que assumem valores dependendo do tipo de codificação usado. Geralmente, uma população inicial para um algoritmo genético é obtida de forma totalmente aleatória para a maioria dos problemas. Porém, podem ser utilizadas informações prévias do problema para tentar gerar uma população inicial bem mais adaptada para o problema.

3.3.3 Função de Adaptabilidade ou Função de Fitness

A função de *fitness* é a função que tem a responsabilidade de classificar e qualificar os indivíduos (cromossomos) dentro de uma população. Esta função vai estar baseada na própria função objetivo do problema, quando esta está disponível.

A análise da função de *fitness* deve ser realizada de forma que, ao longo de sucessivas amostragens do processo evolutivo, sejam fornecidas indicações sobre a localização do ótimo. Ou seja, essa função de *fitness* deve retornar valores para o problema que não tornem a busca cega. Em uma busca cega, todos os algoritmos são equivalentes a uma busca aleatória: encontrar a solução é uma questão de sorte (SILVA, 1999).

3.3.4 Operadores Genéticos

Na teoria de algoritmos genéticos, os operadores genéticos freqüentemente mais utilizados são o *crossover* e a mutação. Porém, dependendo da aplicação, existem muitas variações para tais operadores. A seguir são apresentados os principais aspectos relacionados a estes operadores.

Crossover ou Recombinação

O operador de *crossover* ou recombinação possibilita a criação de novos indivíduos através da combinação de dois ou mais indivíduos. Este operador sustenta a idéia intuitiva de troca de informação entre diferentes soluções candidatas. No algoritmo genético clássico, desenvolvido por HOLLAND (1992), uma probabilidade de *crossover* fixa é atribuída aos indivíduos da população.

O operador de *crossover* mais simples e de fácil implementação é o *crossover* de um ponto. Na aplicação desse operador, dois indivíduos (pais) são selecionados de acordo com a probabilidade estabelecida e a partir de seus cromossomos são gerados dois novos elementos (filhos). A geração dos filhos é estabelecida após a escolha aleatória de um ponto de corte nos cromossomos-pais, de forma que os segmentos a partir do ponto de corte sejam trocados. A Figura 3.2 ilustra o processo de *crossover* simples.

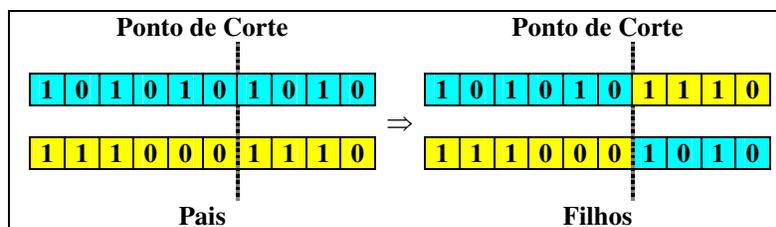


Figura 3.2- *Crossover* Simples

Diversos outros tipos de *crossover* têm sido propostos na literatura. Com uma simples alteração podemos obter uma variação do *crossover* de um ponto que é o *crossover* de dois

pontos, onde ao invés de um, dois pontos de corte são escolhidos e o material genético entre tais pontos será trocado entre os cromossomos.

Um outro tipo de *crossover* bastante utilizado é o *crossover* uniforme (SYSWERDA, 1989). De maneira análoga aos operadores de *crossover* descritos anteriormente, inicialmente os indivíduos são escolhidos de acordo com uma probabilidade, geralmente fixa, e em seguida é feita uma troca de bits ao invés de segmentos de bits (que aqui fazem o papel dos genes) entre cada par de cromossomos de tais indivíduos. Este tipo de *crossover* permite uma combinação de características independentemente da posição relativa dos genes no cromossomo. A Figura 3.3 ilustra o *crossover* uniforme.

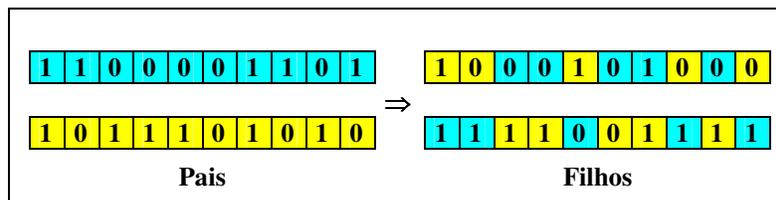


Figura 3.3-Crossover Uniforme

Estudos e vários experimentos desenvolvidos por ESHELMAN *et al.* (1989), com diversos operadores de *crossover*, indicam que o operador de pior desempenho é o *crossover* de um ponto. Porém, não há nenhum operador de *crossover* que apresente um desempenho superior aos demais em todos os casos, concluindo-se através dos resultados que cada operador de *crossover* é particularmente eficiente para um determinado conjunto de problemas e pode ser extremamente ineficiente para outros.

O *crossover* uniforme tende a apresentar um desempenho superior aos demais, o que poderia ser justificado pelo fato do mesmo não considerar a ordenação dos genes ao longo do cromossomo e, portanto, não interferindo no fenótipo de problemas em que a ordenação pode ser qualquer. Entretanto, não há uma razão determinística para explicar o diferencial de desempenho entre os vários tipos de operadores de *crossover*. No *crossover* uniforme, genes selecionados serão trocados por outros genes de mesma posição, mas esta alteração é de caráter individual para cada gene, ou seja, a troca de um gene não interfere na probabilidade de troca dos genes vizinhos.

Todos os operadores de *crossover* descritos até aqui poderiam ser empregados para quase todos os tipos de codificação. Entretanto, alguns modelos foram especialmente

desenvolvidos para uso com codificação em ponto flutuante. Um desses modelos é o chamado *crossover* aritmético (MICHALEWICZ, 1996). Este operador é definido como uma fusão de dois vetores (cromossomos): se x_1^t e x_2^t são dois indivíduos selecionados para *crossover*, os dois filhos resultantes serão $x_1^{t+1} = a.x_2^t + (1-a).x_1^t$ e $x_2^{t+1} = a.x_1^t + (1-a).x_2^t$, sendo a um número aleatório pertencente ao intervalo $[0,1]$. Esse operador é particularmente apropriado para problemas de otimização numérica com restrições, onde a região factível é convexa. Se x_1^t e x_2^t pertencem à região factível, combinações convexas de x_1^t e x_2^t serão também factíveis, garantindo que o *crossover* não vai gerar indivíduos inválidos para o problema em questão. Além do *crossover* aritmético, podemos destacar ainda o *crossover* geométrico e o *crossover* esférico, especialmente desenvolvidos para utilização em problemas de otimização numérica restritos e codificação em ponto flutuante (MICHALEWICZ & SCHOENAUER, 1996).

Ainda tratando-se do tipo de operador de recombinação escolhido, devemos considerar um outro aspecto importante em um algoritmo genético, que diz respeito a como escolher os indivíduos que serão submetidos à recombinação. Neste caso, também existem diversas alternativas possíveis, sendo que entre as mais comuns destacam-se:

- *crossover* entre indivíduos levando-se em conta o *fitness*: são escolhidos indivíduos da população atual por meio de *Roulette Wheel*;
- *crossover* entre um indivíduo aleatório e o melhor indivíduo: é escolhido um indivíduo da população atual aleatoriamente ou por meio de *Roulette Wheel*, sendo o outro elemento o melhor da população.

Mutação

O operador de mutação modifica de forma aleatória um ou mais genes de um cromossomo, de acordo com uma probabilidade denominada taxa de mutação. Geralmente, os valores da taxa de mutação são pequenos e tal operação intuitivamente tende a criar uma variabilidade extra na população, porém com o cuidado para não destruir o progresso já obtido no decorrer do processo evolutivo, comportando-se como uma perturbação de efeito localizado.

Considerando o algoritmo genético clássico desenvolvido por HOLLAND (1992), que usa uma codificação binária, o operador de mutação padrão simplesmente troca o valor do gene selecionado. Portanto, consiste em apenas mudar, em um gene selecionado, o valor 1 para 0 e vice-versa.

Para o caso de problemas com codificação em ponto flutuante, alguns operadores especiais foram desenvolvidos, tais como: a mutação gaussiana (MICHALEWICZ & SCHOENAUER, 1996), a mutação uniforme (MICHALEWICZ, 1996) e a mutação não-uniforme (MICHALEWICZ & SCHOENAUER, 1996).

É bastante empregada também a mutação por inversão, que pode ser feita através de uma simples troca de posição entre genes de um mesmo cromossomo. Este tipo de mutação, usando codificação inteira, é muito comum em problemas tradicionais como, por exemplo, os problemas do Caixeiro Viajante e de *Scheduling* de máquinas (MICHALEWICZ, 1996).

3.3.5 Seleção de Indivíduos para a Próxima Geração

O processo de seleção de indivíduos para a próxima geração, utilizado no algoritmo genético clássico, é denominado *Roulette Wheel* (GOLDBERG, 1989). Neste processo de seleção, cada indivíduo que compõe a população recebe uma probabilidade diretamente proporcional a seu valor de *fitness*, em relação à somatória do *fitness* de todos os elementos da população. O *Roulette Wheel* permite que o indivíduo com maior valor de *fitness* tenha maior probabilidade de passar para a próxima geração. A Figura 3.4 mostra um exemplo:

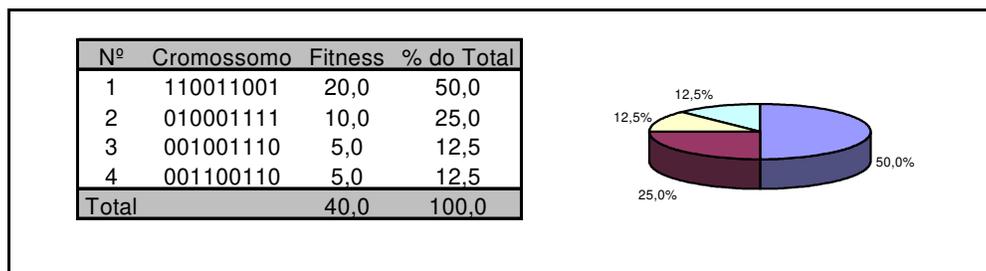


Figura 3.4 – Exemplo de *Roulette Wheel*

Algumas dificuldades podem ser observadas na seleção por *Roulette Wheel*. Dentre elas podemos destacar a perda do melhor indivíduo durante o processo evolutivo, pois a probabilidade do melhor indivíduo ser selecionado não é igual a 1. Uma maneira alternativa seria considerar como solução final o melhor indivíduo encontrado durante todo o processo de evolução do algoritmo, porém esta alternativa não permite que o melhor indivíduo contribua com seu código genético para a produção de descendentes para as gerações posteriores. Assim, uma outra opção consiste em manter sempre o melhor indivíduo na próxima geração. Tal estratégia é conhecida como seleção salvacionista (FOGEL, 1994), (MICHALEWICZ, 1996).

Outra característica do *Roulette Wheel* é que este mecanismo de seleção quando usado para solucionar problemas de otimização em que a função de *fitness* é a própria função objetivo, a priori somente pode ser usado para problemas de maximização. Se o problema de otimização é de minimização, devemos transformar em problema de maximização, da seguinte maneira:

$$\min f(x) = \max \{-f(x)\}.$$

Entretanto, os valores assumidos pela função objetivo f devem ser sempre positivos, caso contrário deve-se adicionar uma constante positiva K ou então utilizar outros mecanismos de escalamento (MICHALEWICZ, 1996).

Um outro mecanismo de seleção muito utilizado é a seleção baseada em rank (BÄCK *et al.*, 1997a). Este critério inicialmente faz uma ordenação dos indivíduos de acordo com o *fitness* e utiliza as posições dos indivíduos após tal ordenação para definir os valores de probabilidade de seleção, usando mapeamentos lineares ou não lineares para estabelecer tal probabilidade.

Pode-se observar nas figuras seguintes, como fica a situação antes e após a mudança do *fitness* para número de ordem.

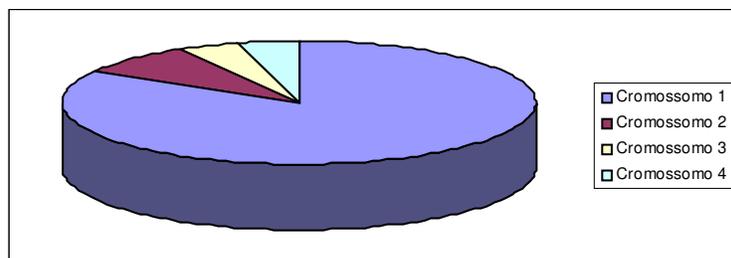


Figura 3.5- Situação antes do ranking (gráfico do *fitness*)

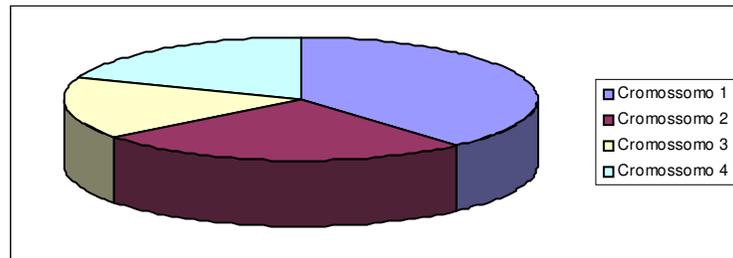


Figura 3.6 - Situação após o ranking (gráfico do número de ordem)

Depois disso, todos os cromossomos têm uma chance mais equiparada de serem selecionados. Porém este método pode levar a uma convergência mais lenta, porque o *fitness* do melhor indivíduo não difere muito do demais indivíduos que compõem a população.

Existem ainda alguns outros mecanismos de seleção que são utilizados, dentre eles os seguintes podem ser destacados:

- Seleção por diversidade: são selecionados os mais diversos indivíduos na população, a partir do melhor indivíduo;
- Seleção bi-classista: são selecionados os P% melhores indivíduos e os (100-P)% piores indivíduos da população;
- Seleção por torneio: dois (ou mais) indivíduos são escolhidos aleatoriamente. Um número aleatório r entre 0 e 1 é gerado. Se $r > k$ (parâmetro) o melhor dos indivíduos é escolhido. Caso contrário o outro é escolhido.
- Seleção *steady-state*: a população original é mantida, com a exceção de alguns poucos indivíduos menos adaptados.
- Seleção aleatória salvacionista: seleciona-se o melhor indivíduo e os outros aleatoriamente.
- Seleção elitista: são selecionados P% dos melhores indivíduos e os outros aleatoriamente ou por meio de *Roulette Wheel*. Incorpora vários casos mencionados anteriormente.

3.3.6 Parâmetros do Algoritmo Genético

Podemos identificar o funcionamento dos algoritmos genéticos como um balanço entre a combinação de exploração de novas regiões no espaço de busca e a exploração de regiões já amostradas. Este balanço exerce de maneira crítica o controle do desempenho dos algoritmos genéticos. Os principais parâmetros de controle são: as taxas de *crossover* e de mutação, além do tamanho da população.

A escolha dos parâmetros de controle ótimo dos algoritmos genéticos é uma tarefa difícil e árdua que vem sendo debatida e investigada, tanto no aspecto analítico como empírico. Entretanto, os seguintes pontos ainda merecem destaque:

- Aumentando a probabilidade de *crossover* aumenta-se a recombinação de blocos construtivos, porém aumenta-se também a destruição de blocos construtivos bons.
- Aumento na probabilidade de mutação tende a transformar a busca genética em busca puramente aleatória, entretanto ajuda a recuperar perda de material genético durante o processo evolutivo.
- Um aumento no tamanho da população aumenta a diversidade e reduz a probabilidade de que o algoritmo genético alcance uma convergência prematura para um ponto de ótimo local. Entretanto, este aumento reflete também no aumento de tempo computacional que uma população levará para convergir para regiões ótimas do espaço de busca.

A escolha dos parâmetros deve ser feita considerando-se as interações dos operadores genéticos. Esta tarefa é caracterizada como um problema de otimização complexo, devido às suas dificuldades. Posteriormente, tornou-se evidente que os parâmetros de controle ótimo dependem do problema junto ao qual algoritmo genético está sendo empregado, ou seja, da natureza da função objetivo do problema.

Diferentes operadores genéticos ou valores de parâmetros de controle podem ser necessários durante o curso de uma execução do algoritmo genético de modo a induzir um balanço exploração/exploração. Devido a estas razões algoritmos genéticos adaptativos têm sido

desenvolvidos para ajustar dinamicamente parâmetros de controle ou operadores genéticos selecionados durante o processo evolutivo.

Uma possível forma de construir algoritmos genéticos adaptativos envolve a aplicação de controladores lógicos *fuzzy* (BÁRDOSY & DUCKSTEIN, 1995), (PEDRYCZ & GOMIDE, 1998) para ajustar parâmetros de controle do algoritmo genético. Embora uma vasta literatura abordando estes métodos adaptativos tenha surgido, ainda existem muitos desafios que podem ser considerados para aplicação destes.

Em (HERRERA & LOZANO, 2001) e (EIBEN *et al.*, 1999) podem ser encontradas algumas técnicas para o controle dos parâmetros durante a execução do algoritmo.

Capítulo 4

METODOLOGIA DESENVOLVIDA

Neste capítulo, é apresentada a metodologia empregada na solução do problema de pré-despacho. Sendo definida a forma como o algoritmo foi implementado, descrevendo as particularidades e os ajustes necessários para o problema específico.

4.1 Procedimento Adotado

Para determinação do programa de operação de um sistema de usinas hidrelétricas é necessário resolver duas questões:

- ✓ Determinar as máquinas que estarão em operação em cada um dos intervalos de tempo do próximo dia;
- ✓ Determinar o ponto de operação em que cada máquina deverá operar.

A primeira questão, definida como Despacho de Máquinas, é usada para solucionar um problema formulado em termos de variáveis inteiras (número de máquinas em cada usina) ou binárias (máquinas ligadas ou desligadas). A segunda questão, denominada como Despacho de Geração, é responsável pela resolução de um problema de despacho econômico para cada intervalo de tempo, sendo formulado somente em termos de variáveis reais (contínuas).

O Despacho de Máquinas foi resolvido através de um algoritmo genético, que avalia várias configurações de máquinas resolvendo seqüencialmente diferentes problemas de Despacho de Geração. O problema de Despacho de Geração é tratado através de um modelo de otimização

não linear, formulado e aplicado após a definição de uma configuração de máquinas. Para solucionar o modelo de Despacho de Geração foi usado o Método de Relaxação Lagrangeana (LUENBERGER, 1989).

A metodologia adotada para a determinação do programa de operação é resumida nos seguintes passos:

1. Gera-se uma população inicial de configurações de máquinas em operação para todos os intervalos de tempo do próximo dia.
2. Verifica-se a factibilidade de cada configuração de máquinas gerada:
 - a. Se a configuração for factível, resolve-se o problema de Despacho de Geração e calcula-se o valor da função de aptidão.
 - b. Se a configuração for infactível, atribuí-se um valor de penalidade linear e calcula-se o valor da função de aptidão.
3. Para $i=1, \dots$, número de iterações:
 - a. Aplicam-se os operadores genéticos na população e geram-se novos indivíduos.
 - b. Verifica-se a factibilidade para todos os novos indivíduos da i -ésima iteração:
 - i. Se factível, resolve-se o problema de Despacho de Geração associado e calcula-se o valor da função de aptidão.
 - ii. Se infactível, atribuí-se um valor de penalidade linear e calcula-se o valor da função de aptidão.
 - c. Seleciona-se a nova população para $(i+1)$ -ésima geração.

Os passos 1, 3a e 3c são relativos ao algoritmos genéticos, no qual em 1 gera-se a população inicial e no passo 3a aplica-se os operadores genéticos na população atual para formar a população da próxima geração. Cada indivíduo de cada geração representa a configuração de máquinas em operação em todos os intervalos do próximo dia. Nos passos 2 e 3b resolve-se o problema de Despacho de Geração correspondente à configuração de máquinas representada pelo respectivo indivíduo. A seguir, cada uma das etapas da metodologia é detalhada.

4.2 Despacho de Máquinas

O Despacho de Máquinas no programa de operação desenvolvido, como foi comentado anteriormente, foi tratado através de um algoritmo genético.

O algoritmo genético implementado possui algumas particularidades que foram desenvolvidas para que o mesmo pudesse ser ajustado da melhor maneira possível ao problema.

As principais características do algoritmo genético implementado são descritas nos tópicos a seguir.

4.2.1 Codificação

A codificação usada denota diretamente o valor das variáveis, porém dependendo de como o problema é exposto, esta codificação pode ser utilizada de duas formas. Na primeira forma, é adotada uma codificação binária (ou *booleana*), onde o cromossomo é composto por genes que indicam o estado de cada máquina em uma usina. O valor “1” indica que a máquina está em operação, e valor “0” o caso contrário. A outra maneira é uma codificação inteira, onde o cromossomo é composto por genes que representam a quantidade de máquinas operando em uma determinada usina num devido intervalo de tempo.

Entretanto, a primeira codificação é mais genérica, ou seja, pode ser utilizada independente das características das máquinas, pois cada máquina é individualmente representada. Já a segunda codificação é utilizada quando todas as máquinas ou conjuntos de máquinas de uma dada usina são iguais. Pode-se notar, pela formulação do problema, que a codificação inteira reduz o espaço de busca e evita a geração de cromossomos diferentes que produzem uma mesma solução.

Usando a codificação com variáveis binárias, o cromossomo é estruturado como mostra a Figura 4.1, onde o tamanho deste cromossomo é dado pelo produto do número de máquinas total do sistema de usinas ($\sum_{i=1}^U n_i$) e a quantidade de intervalos de tempo (T). Por exemplo, se um

sistema tiver três usinas, sendo que as usinas possuam 2, 4 e 5 máquinas, respectivamente, e o período de análise é discretizado em 24 intervalos de tempo, então o cromossomo que representa esse sistema terá tamanho igual a 264 *loci*. Nesta figura, n_i representa o número de máquinas da usina i e U representa o total de usinas hidrelétricas do sistema.

Usinas	1										...	U											
Máquinas	m_1	m_2	...	m_{n_1}	...	m_1	m_2	...	m_{n_1}	...	m_1	m_2	...	m_{n_U}	...	m_1	m_2	...	m_{n_U}				
Estados	0	1	...	0	...	1	0	...	0	...	0	0	...	1	...	1	1	...	0				
Intervalos	1					...	T					...	1					...	T				

Figura 4.1- Cromossomo com codificação binária

Para a codificação inteira, o cromossomo tem o tamanho dado pelo produto do número de usinas (U) e quantidade de intervalos de tempo (T), como é mostrado na Figura 4.2. Neste caso, por exemplo, se o sistema tiver 3 usinas e o período de análise for discretizado em 24 intervalos de tempo, o cromossomo terá um tamanho igual a 72 *loci*, ou seja, independe da quantidade de máquinas que cada usina possui.

Intervalos	1	2	3	...	T	1	2	3	...	T	1	2	3	...	T	...	1	2	3	...	T
Máquinas Ligadas	1	1	2	...	1	1	4	3	...	2	1	3	4	...	3	...	2	1	3	...	4
Usinas	1					2					3					...	U				

Figura 4.2 – Cromossomo com codificação inteira

4.2.2 População Inicial

A população inicial pode ser obtida de forma aleatória ou utilizando uma heurística baseada na curva de carga diária.

O procedimento heurístico para formar a população com base na curva de carga é feito da seguinte maneira:

- i) Inicialmente, um conjunto de probabilidades é calculado, sendo que cada probabilidade é dada pela razão do quociente da demanda de um intervalo de tempo e a demanda máxima da referida curva;

ii) As máquinas que estarão em operação são escolhidas de acordo com as probabilidades estabelecidas no item anterior.

Para qualquer um dos tipos de população inicial, os indivíduos são formados de modo que pelo menos uma máquina em cada usina esteja em operação a cada intervalo de tempo.

4.2.3 Recombinação ou *Crossover*

Neste trabalho, nenhum operador de recombinação especial foi utilizado, ou seja, este operador permanece independente do tipo de codificação estabelecida. O programa desenvolvido permite que o algoritmo genético use o *crossover* uniforme ou *crossover* de um ponto, ou ambos, sendo que os melhores resultados foram obtidos usando-se o primeiro tipo. Entretanto, as seguintes combinações foram utilizadas:

- Melhor indivíduo e indivíduos selecionados de acordo com a probabilidade de recombinação definida;
- Indivíduos selecionados de acordo com a probabilidade de recombinação definida.

4.2.4 Mutação

Ao contrário do operador de recombinação, a mutação depende do tipo de codificação escolhida, devido ao fato deste trabalho tratar um problema de otimização com restrições. Para a codificação binária, a mutação pode ser efetuada sem maiores problemas, bastando-se fazer a inversão dos valores do gene de “0” para “1”, ou vice-versa, onde tais valores estão relacionados com os estados *on/off* de cada máquina numa determinada usina. Entretanto, para uma codificação do tipo inteira, onde cada gene representa o número de máquinas e cada usina possuir um número total de máquinas diferente, operadores de mutação especiais devem ser elaborados de modo a não produzir cromossomos inválidos.

Neste trabalho, foram desenvolvidos dois operadores para a codificação inteira. Um deles simplesmente faz a troca do valor do gene selecionado para um valor que esteja dentro da

faixa permitida $(1, N_U)$. O outro foi elaborado de modo a produzir alterações menos bruscas, sendo dado da seguinte maneira:

$$x_i^{k+1} = \begin{cases} x_i^k + 1 & \text{se } 1 \leq x_i^k < N_U \text{ e } r \leq 0.5, \\ x_i^k - 1 & \text{se } 1 < x_i^k \leq N_U \text{ e } r > 0.5, \\ x_i^k - 1 & \text{se } x_i^k = N_U \text{ e } r \leq 0.5, \\ x_i^k + 1 & \text{se } x_i^k = 1 \text{ e } r > 0.5. \end{cases}$$

onde, x_i^k é um gene selecionado para mutação na iteração k , N_U é valor máximo que x_i^k pode assumir, corresponde ao total de máquinas da usina U , e r é um número aleatório compreendido no intervalo $(0, 1)$.

As seguintes combinações foram usadas no processo de mutação:

- Mutação do melhor indivíduo;
- Mutação de indivíduos escolhidos de acordo com probabilidade de mutação definida.

4.2.5 População Intermediária

A aplicação dos operadores genéticos gera novos indivíduos, formando pequenas subpopulações para cada tipo de operador usado, sendo que a união de todas essas pequenas subpopulações e ainda uma cópia do melhor indivíduo formam uma população intermediária. A população intermediária geralmente possui um tamanho superior à população inicial. É possível também que vários indivíduos sejam gerados aleatoriamente ou obedecendo alguma heurística, visando aumentar a diversidade da população durante a evolução.

4.2.6 Seleção

O processo de seleção de indivíduos que formam a população intermediária para compor a próxima geração do algoritmo genético pode ser efetuado de 3 maneiras:

- Seleção por *Roulette Wheel*;
- Seleção SUS - *Stochastic Universal Sampling* (BÄCK *et al.*, 1997b);
- Seleção bi-classista.

4.2.7 Função de Adaptabilidade

O valor de *fitness*, utilizado para encontrar a probabilidade de cada indivíduo garantir sua sobrevivência durante o processo evolutivo, ou seja, ser selecionado para uma geração subsequente, pode ser obtido utilizando o próprio valor da função objetivo ou através de *ranking* (Veja Seção 3.3.5).

Essa função de adaptabilidade retorna um valor de *fitness* baseado no custo das perdas na geração de energia elétrica, obtidas através da resolução do Despacho de Geração, se o indivíduo (configuração de máquinas) for factível, além de considerar o custo de partidas e paradas efetivadas nas máquinas de cada usina durante o horizonte de estudo. Caso o indivíduo seja infactível, o valor de aptidão é definido de acordo com a seguinte função de penalização:

$$FP = \alpha \sum_{t=1}^T \left(\left| d_t - \sum_{i=1}^U P(n_i^t) \right| \right) + \beta \sum_{i=1}^U \left(\left| m_i - \sum_{t=1}^T P(n_i^t) \right| \right) \quad (4.1)$$

A primeira parcela da função refere-se ao desvio da solução em relação à demanda d_t . Já a segunda parcela refere-se ao desvio da solução em relação à meta m_i . As constantes α e β recebem valores de modo a garantir que o *fitness* das soluções infactíveis sejam sempre piores que o *fitness* de qualquer solução factível.

4.3 O Despacho de Geração

Na medida que uma população de indivíduos é formada a cada iteração do algoritmo genético, cada indivíduo da população precisa ser avaliado. Entretanto, cada indivíduo da

população representa uma configuração de máquinas que devem operar no conjunto de usinas ao longo do período estipulado.

O Despacho de Geração é responsável pela avaliação de cada configuração de máquina. O valor encontrado pelo Despacho de Geração é usado como uma parcela do *fitness* de cada indivíduo utilizado pelo algoritmo genético.

Portanto, associado a cada indivíduo (Despacho de Máquinas) deve ser solucionado o seguinte problema de Despacho de Geração:

$$\min_P \sum_{t=1}^T \sum_{i=1}^U F[P(n_i^t)] \quad (4.2)$$

sujeito a:

$$\sum_{i=1}^U P(n_i^t) = d_t \quad t = 1, \dots, T. \quad (4.3)$$

$$\sum_{t=1}^T P(n_i^t) = m_i \quad i = 1, \dots, U. \quad (4.4)$$

$$P^{\min}(n_i^t) \leq P(n_i^t) \leq P^{\max}(n_i^t) \quad \begin{cases} t = 1, \dots, T; \\ i = 1, \dots, U. \end{cases} \quad (4.5)$$

Neste caso, o valor de n_i^t deixou de ser uma variável deste problema, é agora um parâmetro que representa o número de máquinas em operação na usina i no intervalo t . Assim, o problema acima é formulado somente em termos de variáveis reais.

Este problema foi tratado através de Relaxação Lagrangeana, dualizando-se o problema em relação às restrições de metas energéticas (4.4). A função dual obtida é separável no tempo, e, portanto, para cada t resolve-se um subproblema equivalente a um problema de despacho econômico. Estes subproblemas são coordenados através dos multiplicadores de Lagrange visando o atendimento das metas energéticas.

O problema (4.2) - (4.5) foi resolvido como descrito a seguir.

Dualizando-se o problema (4.2) - (4.5) em relação às restrições de demanda global (4.3) e de metas energéticas (4.4), obtém-se a seguinte função Lagrangeana:

$$L(\lambda, \mu, P) = \sum_{t=1}^T \sum_{i=1}^U F[P(n_i^t)] + \sum_{i=1}^U \lambda_i \left(\sum_{t=1}^T P(n_i^t) - m_i \right) + \sum_{t=1}^T \mu_t \left(\sum_{i=1}^U P(n_i^t) - d_t \right) \quad (4.6)$$

a qual pode ser rescrita como,

$$L(\lambda, \mu, P) = \sum_{t=1}^T \sum_{i=1}^U [L_{it}(\lambda_i, \mu_t)] - \sum_{i=1}^U \lambda_i m_i - \sum_{t=1}^T \mu_t d_t \quad (4.7)$$

onde,

$$L_{it}(\lambda_i, \mu_t, P(n_i^t)) = F_i[P(n_i^t)] + (\lambda_i + \mu_t).P(n_i^t) \quad (4.8)$$

Nesta última equação, λ_i e μ_t são, respectivamente, os multiplicadores de Lagrange associados às restrições de meta energética da usina i e de demanda global do intervalo t . A função (4.7) é separável por usina e por intervalo de tempo.

Assim, a solução do problema (4.2) e (4.5) é obtida resolvendo-se o seguinte problema dual:

$$\max_{\lambda, \mu} h(\lambda, \mu) \quad (4.9)$$

onde λ e β são vetores e o valor da função dual $h(\lambda, \mu)$ é dado por:

$$h(\lambda, \mu) = \min_P L(\lambda, \mu, P) \quad \text{s.a.: } p_i^{\min} \leq p_i^t \leq p_i^{\max} \quad \begin{cases} t = 1, \dots, T; \\ i = 1, \dots, U. \end{cases} \quad (4.10)$$

Tanto a função objetivo como as restrições do problema (4.10) são separáveis por usinas e por intervalo de tempo, assim, o referido problema pode ser reescrito da seguinte forma :

$$h(\lambda, \mu) = \sum_{i=1}^U \sum_{t=1}^T \min_P L_{it}(\lambda_i, \mu_t, P(n_i^t))$$

$$\text{s.a : } p_i^{\min} \leq p_i^t \leq p_i^{\max} \quad \begin{cases} t=1, \dots, T; \\ i=1, \dots, U. \end{cases} \quad (4.11)$$

Ou seja, cada parcela da otimização de (4.11) é obtida pela resolução do problema apresentado a seguir. Sendo que este problema é mono-variável, com variáveis canalizadas.

$$h_{it}(\lambda_i, \mu_t) = \min_P L(\lambda_i, \mu_t, P(n_i^t))$$

$$\text{s.a : } p_i^{\min} \leq p_i^t \leq p_i^{\max} \quad (4.12)$$

4.3.1 Procedimento de resolução

A resolução do problema formulado acima é realizada através de um esquema de decomposição em dois níveis (Figura 4.3). No primeiro nível (coordenador), são fixados os valores dos multiplicadores de Lagrange, e no segundo nível são resolvidos os subproblemas (4.12) para cada usina e para cada intervalo de tempo, em função dos multiplicadores de Lagrange fixados pelo coordenador. Após a resolução dos subproblemas (4.12), a geração ótima de cada usina em cada intervalo de tempo é retornada ao coordenador. Além disso, o coordenador atualiza os valores dos multiplicadores em função dos erros nas restrições de demanda global e de metas verificadas.

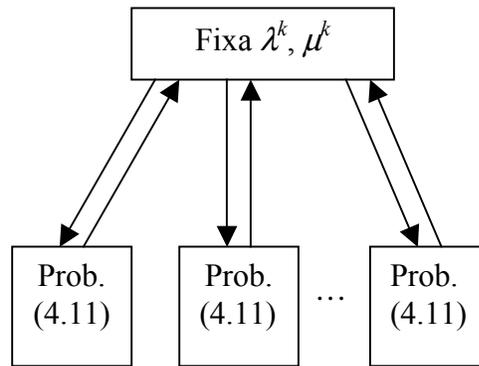


Figura 4.3 –Estrutura de resolução do problema (4.2)-(4.5).

Procedimento:

1. Inicialização: Inicializa-se os multiplicadores de Lagrange (λ , μ).
2. Resolução dos subproblemas: Resolve-se o problema (4.12), para todas as usinas e para todos os intervalos de tempo. Obtém-se assim a geração de cada usina em cada intervalo de tempo ($P(n_i^t)$).
3. Cálculo dos erros: Calcula-se o erro nas restrições de demanda e de metas energéticas na k -ésima iteração do coordenador:

$$erro\ meta_i^k = \sum_{t=1}^T P(n_i^t) - m_i \quad (4.13)$$

$$erro\ demanda_i^k = \sum_i^U P(n_i^t) - d_i \quad (4.14)$$

4. Teste de otimalidade: Se os erros calculados no passo anterior estiverem dentro da precisão especificada, encerra-se o processo; caso contrário, segue-se para o passo (5).
5. Cálculo das direções de busca: Calcula-se as direções de busca através do método das direções conjugadas (LUENBERGER, 1989).
6. Busca unidimensional para atualização dos multiplicadores: Atualiza-se os multiplicadores da forma como é mostrada a seguir, e volta-se ao passo (2).

$$\lambda_i^k = \lambda_i^{k-1} + \alpha \cdot (\text{erro meta}_i^k) \quad (4.15)$$

$$\mu_i^k = \mu_i^{k-1} + \alpha \cdot (\text{erro demanda}_i^k) \quad (4.16)$$

onde, α representa o tamanho do passo, que por sua vez depende de uma busca unidimensional. Para esta implementação, são utilizados o método de direções conjugadas e a busca unidimensional da falsa posição (LUENBERGER, 1989).

Capítulo 5

ANÁLISE DOS RESULTADOS OBTIDOS

Este capítulo apresenta a análise dos resultados obtidos com a aplicação da metodologia desenvolvida, e apresentada no capítulo 4, para o Sistema de Usinas Hidrelétricas do rio Paranapanema. A análise é feita considerando-se dois estudos de caso. O primeiro estudo, Sistema I, considera o sistema operando com um número pequeno de usinas. Para o segundo estudo, Sistema II, considera-se o Sistema do rio Paranapanema completo, ou seja, operando com todas as usinas. Em seguida, apresentam-se outras análises da metodologia. Por último, será apresentado o software desenvolvido.

5.1 Estudo de Caso I

Neste estudo, é proposto o Sistema I constituído de 3 usinas e um total de 11 máquinas. A quantidade de máquinas, os limites operativos para um determinado número de máquinas em operação, e metas diárias de cada usina, são organizados na Tabela 5.1 a seguir:

Usinas	Jurumirim		Chavantes				Taquaruçu				
Máquinas	2		4				5				
	1	2	1	2	3	4	1	2	3	4	5
Potência Min. (MW)	7,0	15	20	30	40	50	30	60	90	110	150
Potência Max. (MW)	48	95	100	200	290	380	120	220	330	420	530
Metas (MW médio)	44,0		222,0				327,0				

Tabela 5.1 – Características das 3 Usinas do Sistema I

A curva de carga considerada para o Sistema I é mostrada na Figura 5.1. Realizaram-se dois estudos, o primeiro onde não são levados em conta os custos de partida e parada das máquinas, e o segundo onde tais custos são considerados.

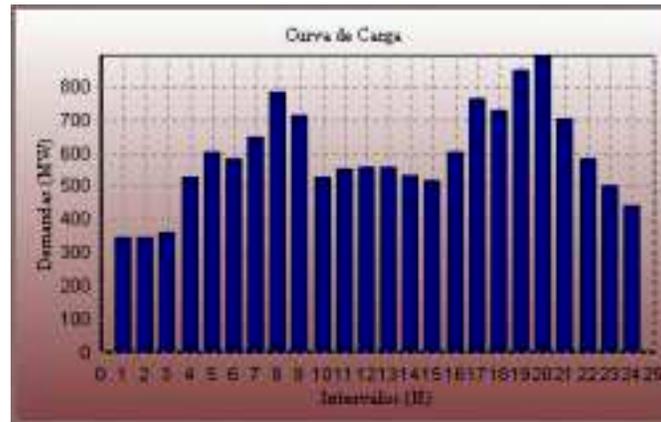


Figura 5.1– Curva de Carga para o Sistema I

5.1.1 Caso sem custos de partida e parada das máquinas

Os algoritmos genéticos usam variáveis aleatórias durante o processo evolutivo e, devido a esta característica, o programa é executado diversas vezes com o objetivo de se verificar o desempenho médio do algoritmo. Os resultados apresentados nesta seção e nas seções posteriores foram encontrados usando-se as configurações do algoritmo genético apresentadas na Tabela 5.2.

Codificação	Inteira
População Inicial	Baseada na curva de carga
Tamanho da População	50 indivíduos
Nº de Gerações	1000
Probabilidade de <i>Crossover</i>	0,25
Probabilidade de Mutação	0,01
Fitness	Baseado em <i>Ranking</i>
Seleção	<i>Roulette Wheel</i>

Tabela 5.2 – Configuração do Algoritmo Genético

A Tabela 5.3 mostra os principais resultados de cada execução realizada. Nesta tabela são apresentados os custos (*fitness*) e as perdas iniciais, para a primeira iteração do algoritmo que

produz uma solução factível, os custos e as perdas finais quando o algoritmo atinge o critério de parada. Na última coluna, mostra-se o ganho da solução final em relação à solução factível inicial, em termos de perdas.

	Custos (US\$)		Perdas (MW)		Redução
	Inicial	Final	Inicial	Final	Custos – Perdas
	13574,93	9712,39	796,42	569,81	28,5%
	14334,87	9713,82	841,00	569,89	32,2%
	12789,72	9716,50	750,35	570,05	24,0%
	13556,07	9728,81	795,31	570,77	28,2%
	13651,35	9736,39	800,90	571,22	28,7%
	14092,70	9742,77	826,79	571,59	30,9%
	12907,34	9747,80	757,25	571,89	24,5%
	13137,45	9764,79	770,75	572,88	25,7%
	13512,10	9767,04	792,73	573,01	27,7%
	14186,58	9781,05	832,30	573,84	31,1%
	13601,55	9787,38	797,98	574,21	28,0%
	12434,95	9788,63	729,54	574,28	21,3%
	14590,21	9790,37	855,98	574,38	32,9%
	13793,69	9804,13	809,25	575,19	28,9%
	13970,84	9811,33	819,64	575,61	29,8%
	12836,50	9814,35	753,09	575,79	23,5%
	12566,75	9820,59	737,27	576,16	21,9%
	13267,96	9832,06	778,41	576,83	25,9%
	12819,26	9835,65	752,08	577,04	23,3%
	11814,23	9842,98	693,12	577,47	16,7%
Média	13371,95	9776,94	784,51	573,60	26,7%
Desvio Padrão	707,93	42,64	41,53	2,50	

Tabela 5.3 – Resultados das Execuções – Sistema I sem Custos de Partida e Parada

A partir dos valores apresentados na Tabela 5.3, verifica-se que o Algoritmo Genético (AG), mesmo possuindo parâmetros aleatórios, consegue na maioria das vezes atingir custos e ganhos satisfatórios. Em todos os casos, os custos finais obtidos são muito próximos, indicando uma regularidade no comportamento da metodologia.

Os resultados obtidos na iteração inicial do algoritmo genético geralmente são infactíveis, porém entre a segunda e quarta iteração dos casos analisados, o algoritmo consegue encontrar soluções factíveis. É feita uma comparação entre a primeira solução factível encontrada e a melhor solução encontrada em termos de perdas (MW) ou custos (US\$) em cada execução do programa, pois se torna difícil realizar esta comparação considerando-se uma solução infactível.

A seguir, apresentam-se várias figuras que mostram as principais características do melhor resultado obtido na Tabela 5.3. Na Figura 5.2, é ilustrado um aspecto do algoritmo genético: o desempenho do processo de evolução do melhor indivíduo versus a média dos indivíduos factíveis ao longo de todas as iterações. Na Figura 5.3, é apresentada a configuração de máquinas em cada usina, e na Figura 5.4 mostra-se as curvas de produção de energia.

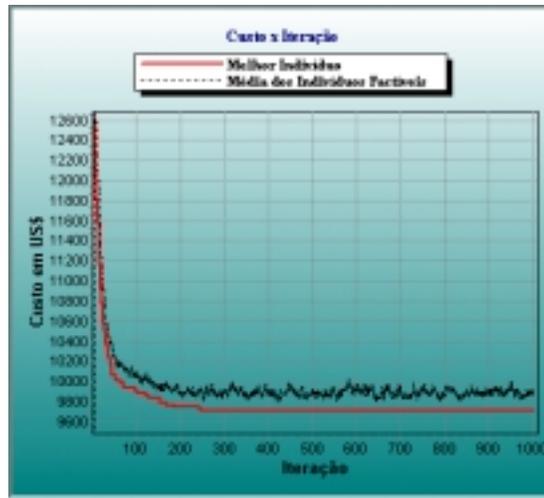


Figura 5.2 - Curva de Evolução do AG - Melhor Resultado sem Custos de Partida e Parada – Sistema I

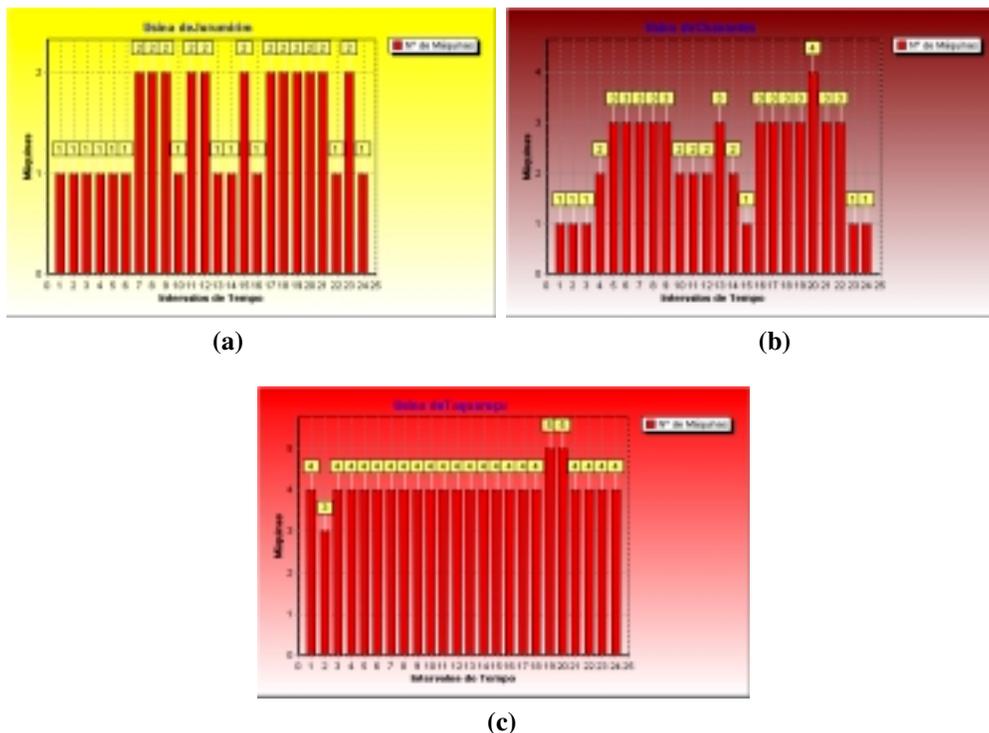


Figura 5.3 – Configuração de Máquinas - Melhor Resultado sem Custos de Partida e Parada - Sistema I

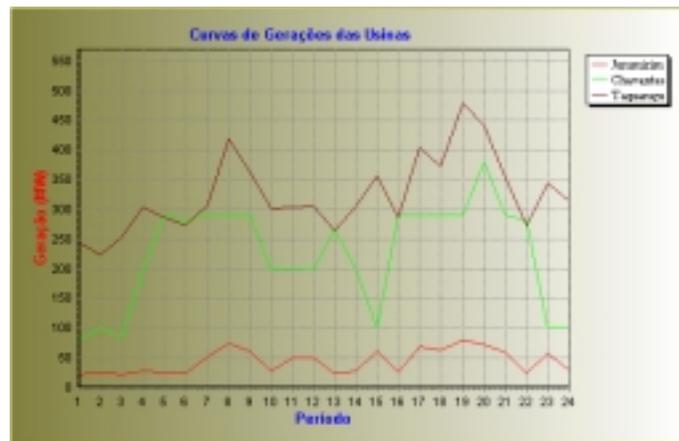


Figura 5.4 – Curvas de Gerações - Melhor Resultado sem Custos de Partida e Parada - Sistema I

O comportamento de um outro resultado, o segundo melhor da Tabela 5.3, é apresentado a seguir (Figura 5.5, Figura 5.6, Figura 5.7). Neste caso, pode-se observar que, apesar da pequena diferença em termos de perdas entre tais resultados, da ordem de 0.02%, verifica-se uma configuração de máquinas diferente, assim como uma diferente evolução do algoritmo genético, confirmando o aspecto combinatório do problema.

Nos dois casos, verifica-se através da curva de evolução do algoritmo genético que, apesar de terem sido usadas 1000 iterações, o processo convergiu bem antes. Para melhor resultado a convergência foi alcançada antes de 300 iterações, enquanto que para o segundo melhor foram necessárias quase 800 iterações.

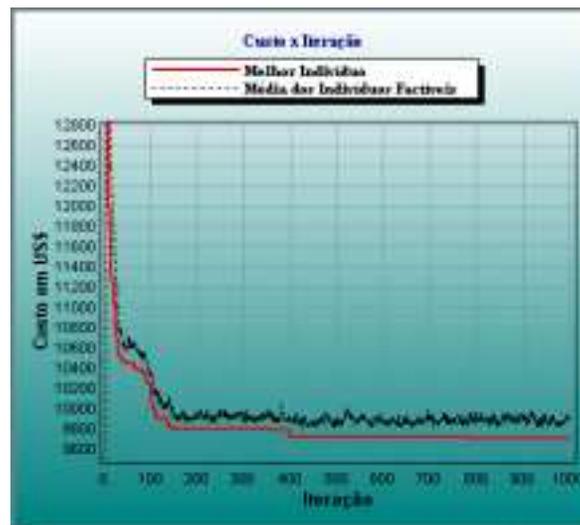


Figura 5.5 - Curva de Evolução do AG - 2º Melhor Resultado sem Custos de Partida e Parada – Sistema I

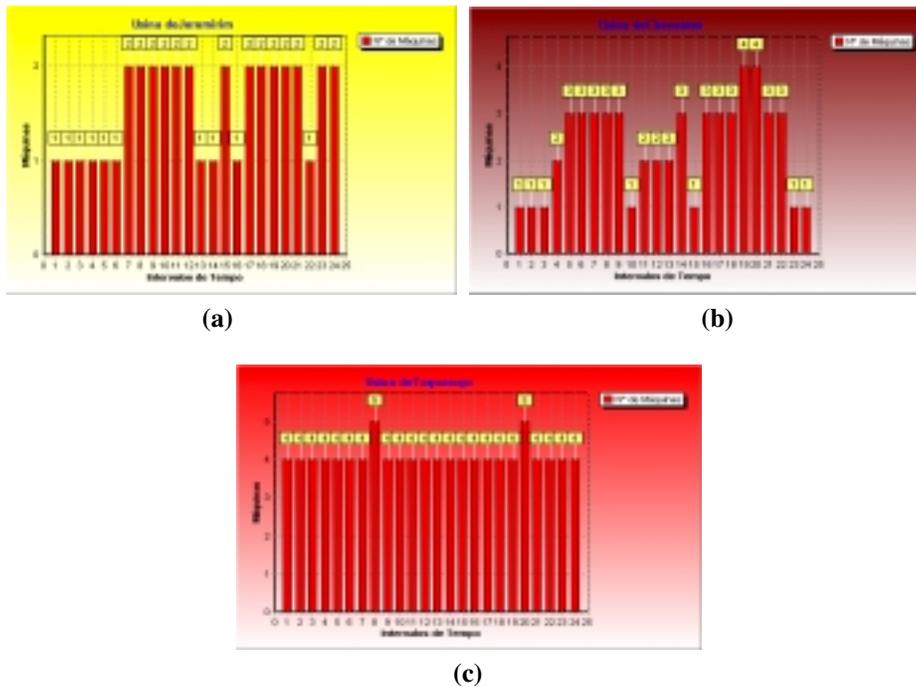


Figura 5.6 – Configuração de Máquinas - 2º Melhor Resultado sem Custos de Partida e Parada – Sistema I

A seguir, na Figura 5.7, é apresentada a curva de geração das usinas para a configuração de máquinas da Figura 5.6, relativa ao segundo melhor resultado obtido. Comparando-se com a curva verificada para a configuração de máquinas do melhor resultado, nota-se alguns intervalos de tempo onde existem deslocamentos de geração de uma usina para outra. Porém, no geral a operação em termos de geração é bastante semelhante.



Figura 5.7 – Curvas de Gerações para o 2º Melhor Resultado sem Custos de Partida e Parada - Sistema I

5.1.2 Caso com custos de partida e parada das máquinas

Na Tabela 5.4, são apresentados os resultados de várias execuções do programa. Porém, desta vez estão sendo considerados os custos de partida e parada das máquinas.

	Custos Iniciais (US\$)			Custos Finais (US\$)			Perdas (MW)		Redução		
	Total	Perda	Part./Par.	Total	Perda	Part./Par.	Inicial	Final	Total	Perdas	Part./Par.
28945,41	12856,02	16089,39	13321,13	9940,13	3381,00	754,24	583,17	54,0%	22,7%	79,0%	
31231,36	12497,91	18733,45	12835,59	10193,76	2641,83	733,23	598,05	58,9%	18,4%	85,9%	
27789,60	13460,10	14329,50	12538,15	10235,35	2302,80	789,68	600,49	54,9%	24,0%	83,9%	
29327,18	14083,43	15243,75	13407,67	10285,81	3121,86	826,25	603,45	54,3%	27,0%	79,5%	
29123,17	12422,23	16700,94	12598,12	10295,18	2302,94	728,79	604,00	56,7%	17,1%	86,2%	
31126,22	13488,39	17637,83	13115,79	10332,85	2782,94	791,34	606,21	57,9%	23,4%	84,2%	
29200,32	13554,52	15645,80	13647,49	10367,45	3280,04	795,22	608,24	53,3%	23,5%	79,0%	
32813,93	13266,98	19546,95	12899,42	10398,47	2500,95	778,35	610,06	60,7%	21,6%	87,2%	
28811,21	13771,51	15039,70	12937,28	10442,11	2495,17	807,95	612,62	55,1%	24,2%	83,4%	
28969,33	13274,13	15695,20	14101,11	10499,21	3601,90	778,77	615,97	51,3%	20,9%	77,1%	
28863,77	12124,45	16739,32	13643,05	10521,20	3121,85	711,32	617,26	52,7%	13,2%	81,4%	
31136,47	13831,68	17304,79	13500,13	10570,63	2929,50	811,48	620,16	56,6%	23,6%	83,1%	
29581,39	13371,63	16209,76	13072,55	10571,65	2500,90	784,49	620,22	55,8%	20,9%	84,6%	
27722,56	14140,02	13582,54	13245,11	10580,34	2664,77	829,57	620,73	52,2%	25,2%	80,4%	
29252,30	14019,85	15232,45	13219,43	10600,46	2618,97	822,52	621,91	54,8%	24,4%	82,8%	
31047,00	14164,91	16882,09	13413,97	10602,67	2811,30	831,03	622,04	56,8%	25,1%	83,3%	
30576,38	13423,96	17152,42	13277,69	10612,90	2664,79	787,56	622,64	56,6%	20,9%	84,5%	
31685,26	15136,47	16548,79	13134,31	10644,60	2489,71	888,03	624,50	58,5%	29,7%	85,0%	
33525,00	14345,92	19179,08	13335,60	10670,85	2664,75	841,65	626,04	60,2%	25,6%	86,1%	
26487,63	13192,32	13295,31	13638,79	10680,74	2958,05	773,97	626,62	48,5%	19,0%	77,8%	
Média	29860,77	13521,32	16339,45	13244,12	10452,32	2791,80	793,27	613,22	55,5%	22,5%	82,7%
D. Padrão	1749,95	715,62	1685,67	377,16	193,58	357,92	41,98	11,36			

Tabela 5.4 – Resultados das Execuções – Sistema I com Custos de Partida e Parada

As atribuições do melhor resultado encontrado são verificadas através das figuras expostas a seguir. Inicialmente, tem-se o desempenho do algoritmo genético (Figura 5.8), em seguida a configuração de máquinas (Figura 5.9), e por último a curva de geração de energia em cada usina (Figura 5.10).

É importante ressaltar que, o melhor resultado está sendo considerado do ponto de vista de perdas e não dos custos totais. Os custos totais envolvem tanto o valor dos custos referentes às perdas quanto os custos de partida e parada das máquinas.

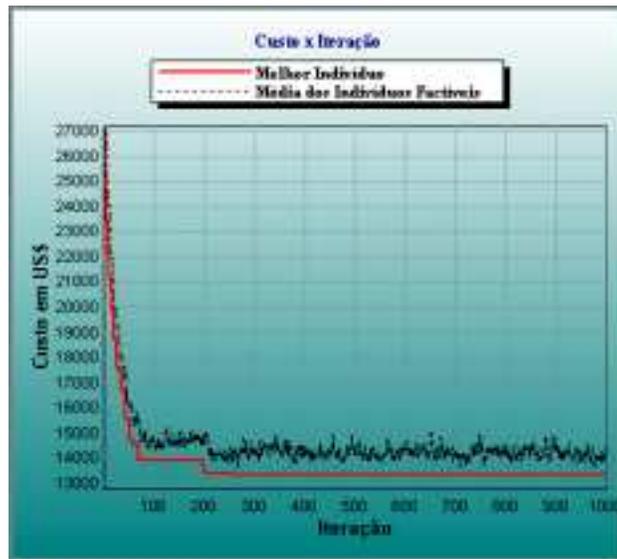


Figura 5.8 - Curvas de Evolução do AG - Melhor Resultado com Custos de Partida e Parada – Sistema I

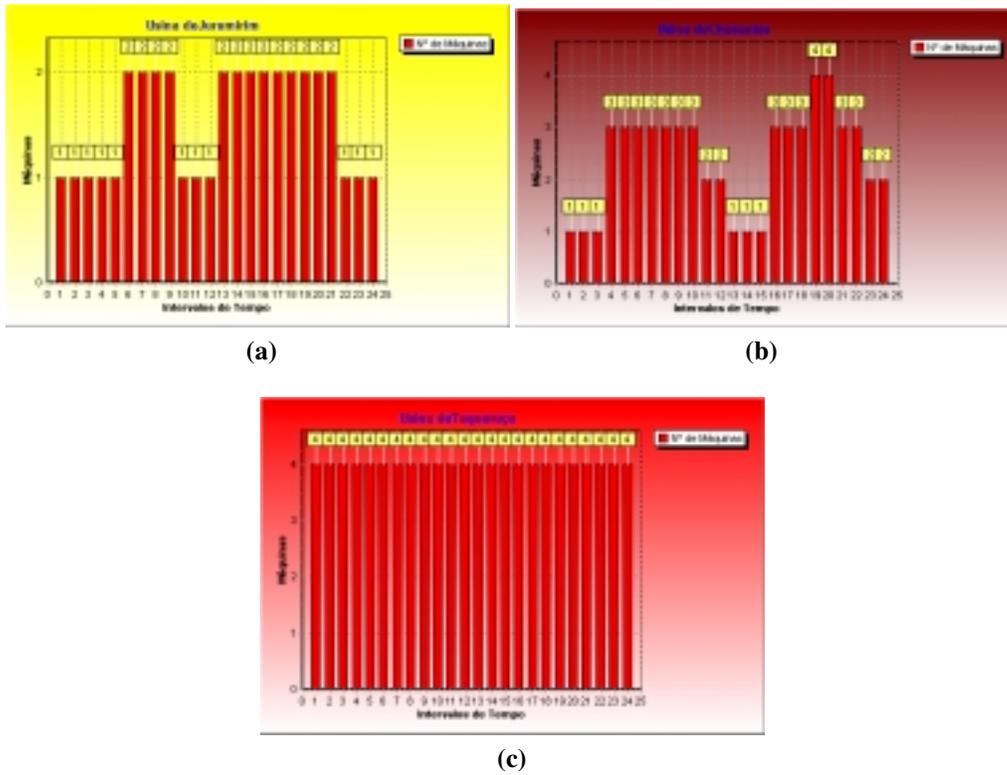


Figura 5.9 - Configuração de Máquinas - Melhor Resultado com Custos de Partida e Parada – Sistema I

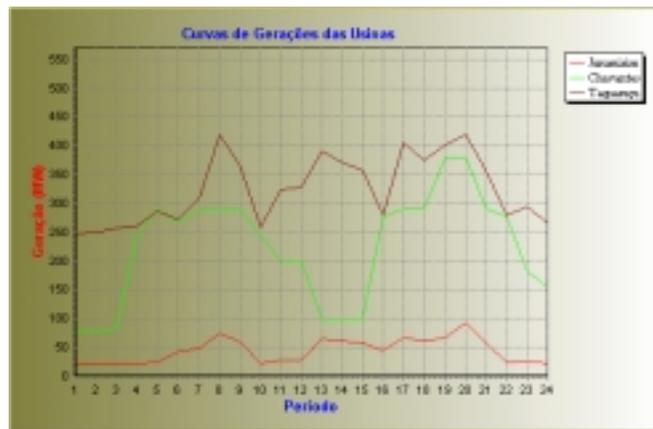


Figura 5.10 - Curvas de Geração - Melhor Resultado com Custos de Partida e Parada – Sistema I

Nas figuras a seguir (Figura 5.11, Figura 5.12, Figura 5.13) verifica-se o comportamento do metodologia para o segundo melhor resultado encontrado dentre as execuções realizadas e apresentadas na Tabela 5.4.

A diferença de maior destaque entre as configurações de máquinas em ambos os casos é verificada na usina de Taquaruçu. Para o melhor resultado a operação desta usina é realizada durante todo período com 4 máquinas, ou seja, não sofre nenhuma penalização por partida e parada de máquinas. Na outra solução, pelo menos no horário de ponta, esta usina opera com todas suas máquinas.

A curva de evolução do algoritmo genético para esta execução apresenta um comportamento mais suave, sendo a convergência atingida somente após 500 iterações. No caso anterior, o comportamento desta curva é bem mais brusco, sendo a convergência atingida pouco antes das 300 iterações.

Através das curvas de geração das usinas, em ambos os casos, são mostrados o comportamento das usinas durante o horizonte de estudo, onde:

- A usina de Jurumirim apresenta uma geração bem semelhante para os dois casos.
- A curva geração da usina de Chavantes apresenta uma queda bem acentuada nos intervalos entre 13 e 15 horas no primeiro caso, operando somente com 1 máquina nestes intervalos. Já no segundo resultado, a operação da usina de Chavantes com apenas 1 máquina ocorre somente nos 3 primeiros intervalos de tempo.

- A geração da usina de Taquaruçu, apesar desta usina funcionar com a mesma quantidade de máquinas durante todo o período no primeiro caso e em grande parte para o segundo, apresenta diferentes valores de geração em ambos os casos, mostrando o ajuste da operação para um ponto de operação que respeite as restrições de demanda e meta da usina.

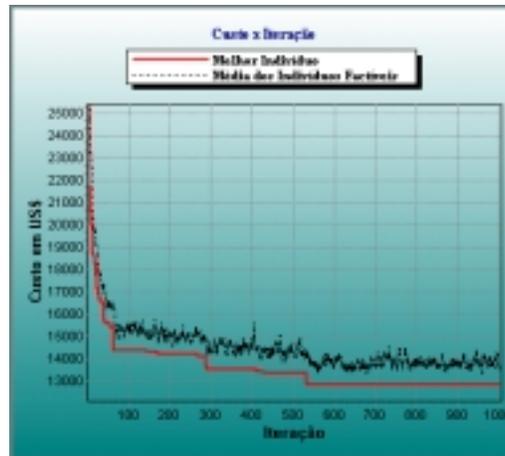


Figura 5.11 - Curva de Evolução do AG – 2º Melhor Resultado com Custos de Partida e Parada – Sistema I

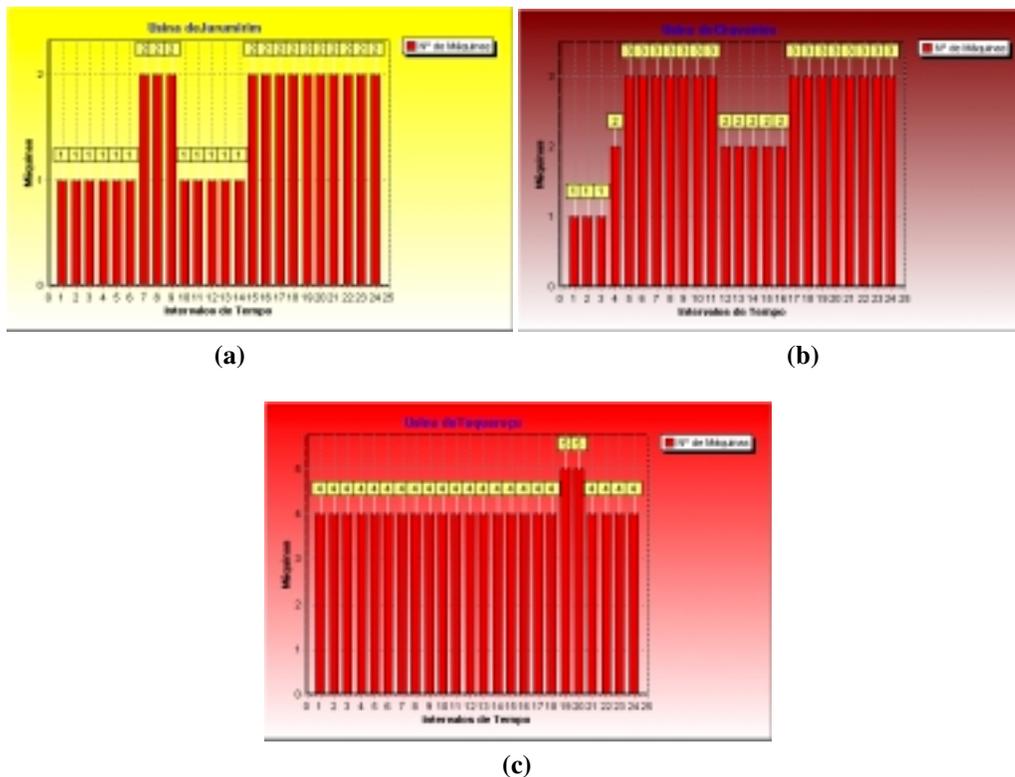


Figura 5.12 - Configuração de Máquinas - 2º Melhor Resultado com Custos de Partida e Parada – Sistema I

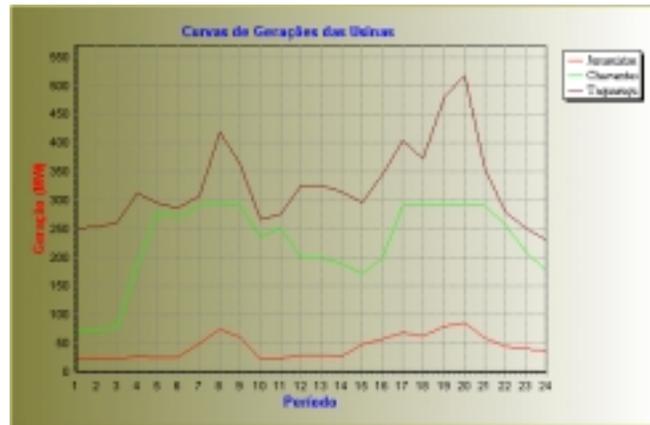


Figura 5.13 - Curvas de Gerações - 2º Melhor Resultado com Custos de Partida e Parada – Sistema I

Finalmente, é importante destacar que a inclusão do custo de partida e parada minimiza as mudanças de configuração, que é um aspecto importante para a operação em tempo real do Sistema.

5.1.3 Comparações entre os casos com e sem custos de partida/partida

As principais relações apresentadas entre os casos com e sem custos de partida/parada das máquinas podem ser enumeradas da seguinte maneira:

1. As perdas finais nas usinas apresentam na média uma diferença de 6,46% a favor do caso sem custos de partida/parada;
2. As configurações de máquinas apresentam, no caso em que são considerados os custos de partida/parada, um comportamento mais suave sem tantas mudanças no número de máquinas em cada usina ao longo do período;
3. Em termos de ganhos envolvendo os custos totais finais e iniciais, o caso que envolve os custos de partida e parada é bem superior ao caso que não os considera. Porém, verifica-se que esses resultados estão totalmente ligados justamente às partidas e paradas. Na média, os ganhos envolvendo somente os custos de partida / parada chegam a 82,7%.

5.2 Estudo de Caso II

Nas seções anteriores, foi feita análise da metodologia quando aplicada ao Sistema I. Agora uma nova análise será feita considerando-se o Sistema II.

Ao operar somente com 3 usinas o sistema contava com um total de 11 máquinas, quando todas as usinas estão em funcionamento o sistema pode contar com um total de até 29 máquinas em operação. A quantidade de máquinas, os limites operativos para um determinado número de máquinas em operação, e as meta diárias de cada usina são organizados na Tabela 5.5.

Este estudo considera uma segunda curva de carga (Figura 5.14) a ser suprida pelo Sistema de usinas. De maneira análoga ao estudo anterior, é feita uma análise considerando a operação do sistema inicialmente sem aplicação dos custos de partida e parada das máquinas. Depois, uma outra análise verifica o comportamento do sistema quando os custos de partida e parada estão presentes.

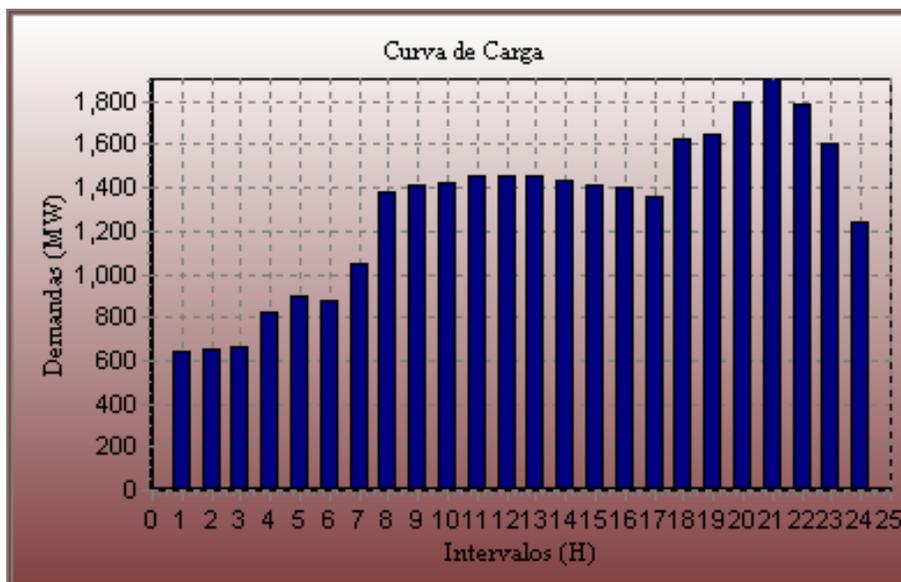


Figura 5.14 – Curva de Carga para o Sistema II

Usinas	Nº Total de Máquinas	Máquinas em Operação	Potência Total (MW)		Meta
			Mínima	Máxima	
Jurumirim	2	1	7	48	23,3
		2	11	95	
Salto Grande	4	1	4	19	49,0
		2	6	37,2	
		3	7	54,6	
		4	9	72,6	
Chavantes	4	1	20	100	109,5
		2	32	200	
		3	42	294	
		4	50	388	
Canoas2	3	1	6	28	45,0
		2	12,5	56	
		3	18,5	82,5	
Canoas1	3	1	22,09	31	55,7
		2	32,3	62	
		3	38	93	
Cativara	4	1	20	134,66	499,16
		2	43	266,38	
		3	60	395,16	
		4	80	521	
Taquaruçu	5	1	30	110	267,37
		2	61	218	
		3	90	330	
		4	120	424	
		5	150	522	
Rosana	4	1	10	99,23	260,0
		2	26	189,95	
		3	33	271,6	
		4	46,8	349,6	

Tabela 5.5 – Características das 8 Usinas do Sistema II

5.2.1 Caso sem custos de partida e parada das máquinas

Os resultados obtidos quando se desconsidera o custo de partida e parada das máquinas para várias execuções do programa são apresentados na Tabela 5.6 a seguir.

	Custos (US\$)		Perdas (MW)		Redução
	Inicial	Final	Inicial	Final	Custos - Perdas
	54.661,43	43.497,36	3206,89	2551,91	20,4%
	54.285,48	43.564,26	3184,83	2555,84	19,7%
	54.041,64	43.579,27	3170,53	2556,72	19,4%
	53.776,88	43.640,27	3154,99	2560,30	18,8%
	56.807,68	43.673,58	3332,81	2562,25	23,1%
	55.153,05	43.785,37	3235,73	2568,81	20,6%
	54.823,12	43.858,72	3216,38	2573,11	20,0%
	57.123,10	43.922,86	3351,31	2576,88	23,1%
	53.190,40	43.957,89	3120,59	2578,93	17,4%
	53.677,27	44.013,16	3149,15	2582,17	18,0%
	56.844,58	44.055,69	3334,97	2584,67	22,5%
	52.659,34	44.087,02	3089,43	2586,51	16,3%
	53.757,22	44.092,91	3153,84	2586,85	18,0%
	56.762,58	44.119,05	3330,16	2588,39	22,3%
	55.052,65	44.127,77	3229,84	2588,90	19,8%
	52.614,13	44.160,89	3086,78	2590,84	16,1%
	53.557,66	44.166,85	3142,13	2591,19	17,5%
	56.060,98	44.167,12	3289,00	2591,21	21,2%
	53.318,68	44.210,06	3128,11	2593,73	17,1%
	53.649,73	44.215,73	3147,53	2594,06	17,6%
Média	54.590,88	43.944,79	3202,75	2578,16	19,4%
Desvio Padrão	1.444,22	239,58	84,73	14,06	

Tabela 5.6 – Resultados das Execuções – Sistema II sem Custos de Partida e Parada

Os dados fornecidos na tabela anterior mais uma vez mostram o desempenho do programa. Nota-se através dos resultados que a média dos valores encontrados está bem próxima do melhor resultado encontrado. Um outro ponto a ser observado é que apesar do desvio padrão dos valores iniciais ser relativamente elevado, este desvio reduz significativamente quando os resultados finais são atingidos.

Os resultados também apontam, na média, uma redução satisfatória nas perdas das usinas, traduzindo uma economia de aproximadamente 20% na operação do sistema em relação à primeira solução factível.

O melhor resultado fornecido na Tabela 5.6 é analisado através de figuras que mostram o comportamento do algoritmo genético (Figura 5.15), as curvas de produção de energia de cada usina (Figura 5.16), e a configuração de máquinas (Figura 5.17). Este resultado mantém uma pequena diferença, cerca de 0,16%, em relação ao segundo melhor.

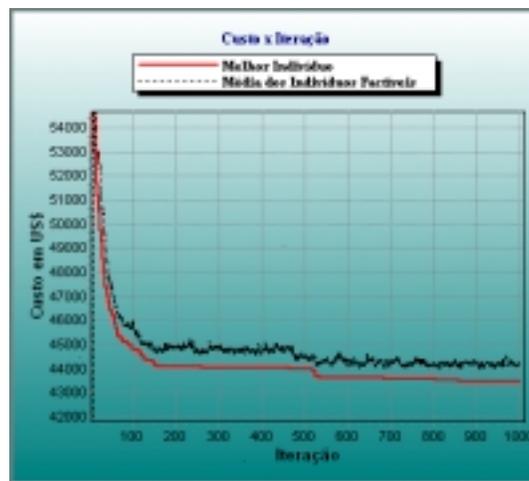


Figura 5.15 – Curva de Evolução do AG - Melhor Resultado sem Custos de Partida e Parada - Sistema II

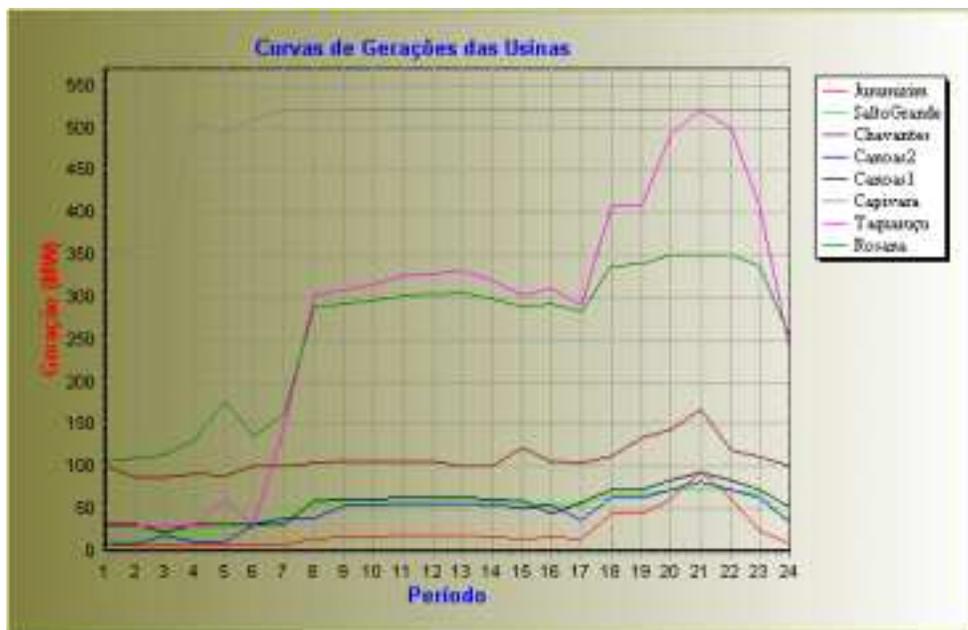


Figura 5.16 – Curvas de Gerações - Melhor Resultado sem Custos de Partida e Parada - Sistema II

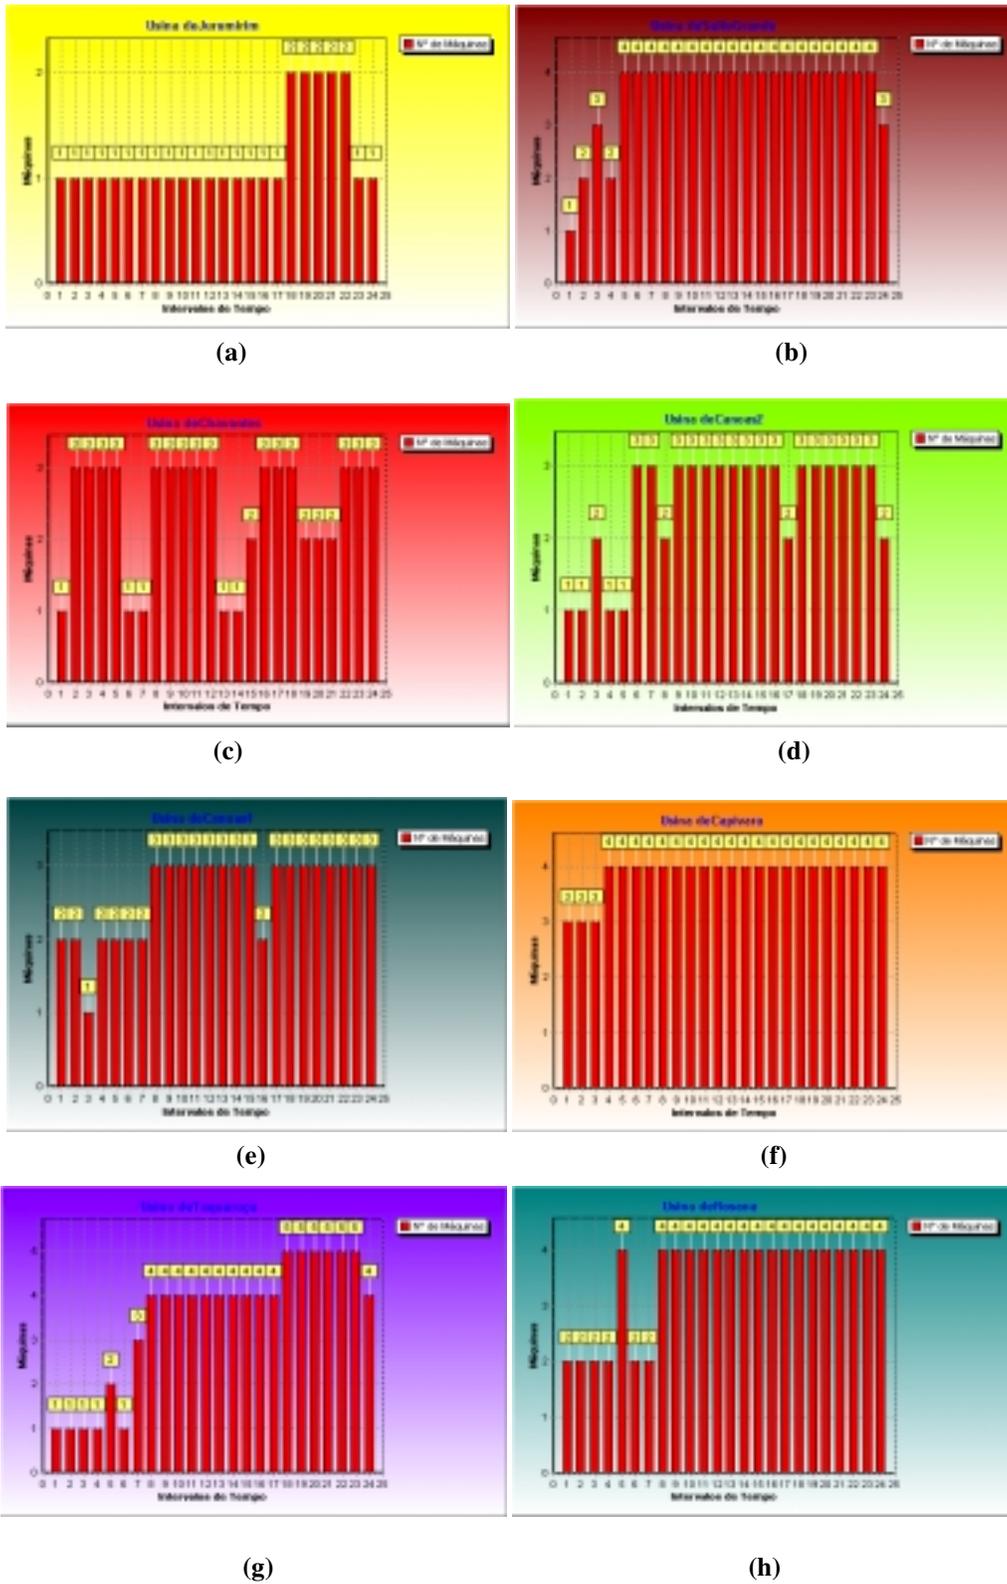


Figura 5.17 – Configuração de Máquinas - Melhor Resultado sem Custos de Partida e Parada - Sistema II

5.2.2 Caso com custos de partida e parada das máquinas

O caso em que são considerados os custos de partida e parada das máquinas é apresentado na Tabela 5.7. Essa tabela mostra dados análogos aos apresentados para o sistema operando com apenas 3 usinas.

Custos Iniciais (US\$)			Custos Finais (US\$)			Perdas (MW)		Redução			
Total	Perda	Part./Par.	Total	Perda	Part./Par.	Inicial	Final	Total	Perdas	Part./Par.	
74.126,22	54.933,65	19.192,57	48.844,41	45.271,86	3.572,55	3222,86	2656,02	34,1%	17,6%	81,4%	
74.757,05	53.088,02	21.669,03	49.285,48	45.381,29	3.904,19	3114,58	2662,44	34,1%	14,5%	82,0%	
75.849,96	53.554,54	22.295,42	49.203,78	45.631,68	3.572,10	3141,95	2677,13	35,1%	14,8%	84,0%	
78.639,40	52.915,69	25.723,71	49.392,80	45.663,21	3.729,59	3104,47	2678,98	37,2%	13,7%	85,5%	
75.309,68	54.312,87	20.996,81	49.285,20	45.704,12	3.581,08	3186,44	2681,38	34,6%	15,9%	82,9%	
71.697,27	53.074,89	18.622,38	50.023,89	45.717,76	4.306,13	3113,81	2682,18	30,2%	13,9%	76,9%	
74.317,74	53.569,03	20.748,71	49.081,10	45.746,39	3.334,71	3142,80	2683,86	34,0%	14,6%	83,9%	
73.583,40	52.213,95	21.369,45	48.761,92	45.790,20	2.971,72	3063,30	2686,43	33,7%	12,3%	86,1%	
70.609,04	51.947,88	18.661,16	50.021,50	45.853,61	4.167,89	3047,69	2690,15	29,2%	11,7%	77,7%	
73.302,26	53.473,06	19.829,20	49.927,43	45.924,34	4.003,09	3137,17	2694,30	31,9%	14,1%	79,8%	
69.895,55	52.396,16	17.499,39	48.959,50	45.967,13	2.992,37	3073,99	2696,81	30,0%	12,3%	82,9%	
78.292,09	55.314,43	22.977,66	49.816,28	46.035,31	3.780,97	3245,20	2700,81	36,4%	16,8%	83,5%	
80.583,35	60.299,59	20.283,76	49.320,84	46.108,26	3.212,58	3537,67	2705,09	38,8%	23,5%	84,2%	
78.466,33	56.728,49	21.737,84	49.734,48	46.138,26	3.596,22	3328,16	2706,85	36,6%	18,7%	83,5%	
75.433,46	53.253,35	22.180,11	50.546,53	46.206,44	4.340,09	3124,28	2710,85	33,0%	13,2%	80,4%	
76.738,65	54.459,12	22.279,53	48.976,15	46.275,47	2.700,68	3195,02	2714,90	36,2%	15,0%	87,9%	
76.622,67	56.185,09	20.437,58	49.264,66	46.294,05	2.970,61	3296,28	2715,99	35,7%	17,6%	85,5%	
76.633,86	56.083,67	20.550,19	50.260,68	46.330,70	3.929,98	3290,33	2718,14	34,4%	17,4%	80,9%	
77.168,75	53.355,45	23.813,30	50.776,69	46.406,55	4.370,14	3130,27	2722,59	34,2%	13,0%	81,6%	
73.502,38	54.732,69	18.769,69	51.059,81	46.418,48	4.641,33	3211,07	2723,29	30,5%	15,2%	75,3%	
Média	75.276,46	54.294,58	20.981,87	49.627,16	45.943,25	3.683,90	3185,37	2695,41	34,0%	15,3%	82,3%
D. Padrão	2.757,22	1.952,42	1.974,22	660,66	331,52	538,53	114,54	19,45			

Tabela 5.7 – Resultados das Execuções - Sistema II com Custos de Partida e Parada

Novamente apresenta-se a curva de desempenho do processo evolutivo (Figura 5.18), a configuração de máquinas nas usinas (Figura 5.20), e as curvas de produção de energia das usinas do sistema (Figura 5.19), considerando-se o melhor resultado encontrado com relação as perdas. Pode-se observar que existe apenas uma pequena diferença entre os resultados de perdas encontrados. Em relação ao primeiro e ao segundo melhor resultado, a diferença é apenas de aproximadamente 2,4 %.

O desempenho da metodologia quando aplicado ao sistema II é muito similar ao caso do Sistema I e, portanto, valem as mesmas conclusões.

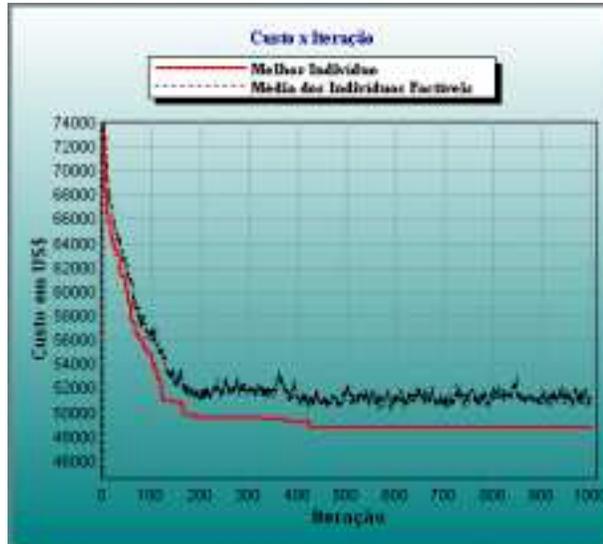


Figura 5.18 – Curva de Evolução do AG - Melhor Resultado com Custos de Partida e Parada – Sistema II

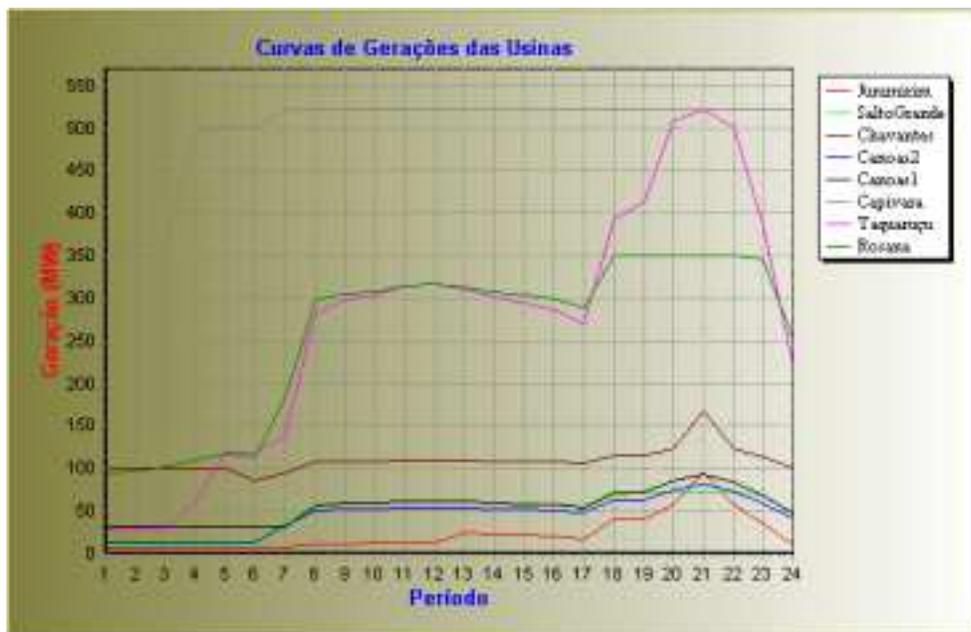
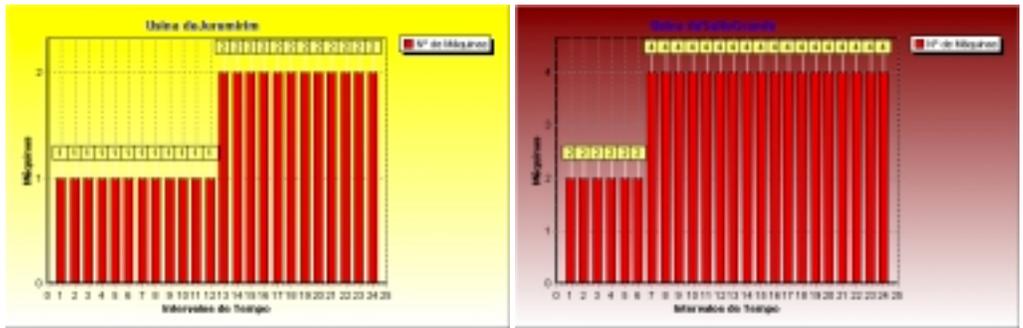
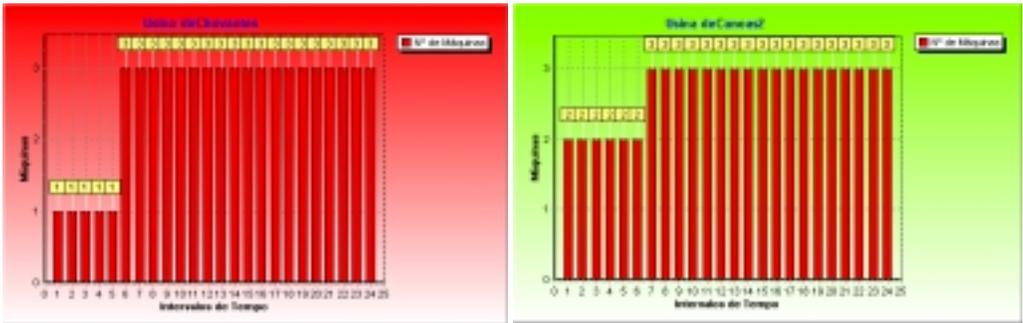


Figura 5.19 – Curvas de Gerações - Melhor Resultado com Custos de Partida e Parada - Sistema II



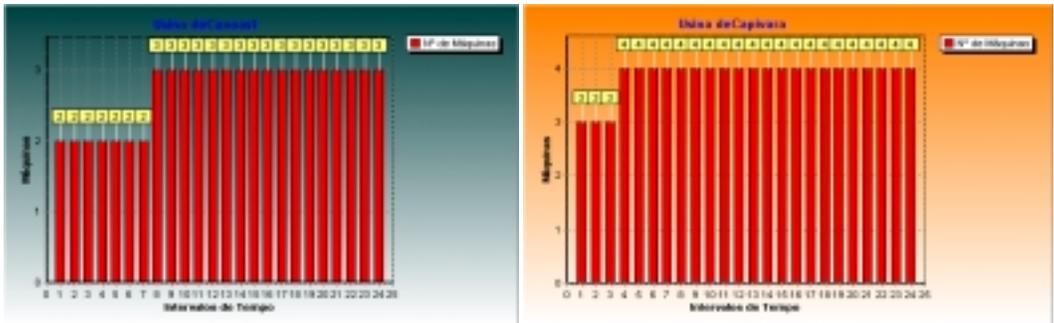
(a)

(b)



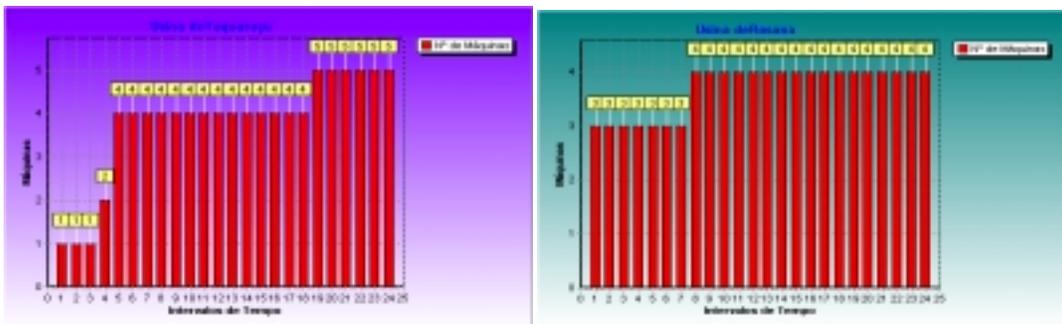
(c)

(d)



(e)

(f)



(g)

(h)

Figura 5.20 – Configuração de Máquinas - Melhor Resultado com Custos de Partida e Parada - Sistema II

5.3 Influência da População Inicial do Algoritmo Genético

Para dar uma idéia do comportamento de um algoritmo genético numa dada aplicação, é comum computar-se estatísticas para um conjunto de resultados correspondentes, obtidos a cada nova inicialização, sendo que um Algoritmo Genético robusto deve sofrer pouca influência dos mecanismos aleatórios, retornando sempre soluções de boa qualidade.

No algoritmo genético implementado, foram feitos vários testes para observarmos as características e os parâmetros que melhor se ajustaram aos casos em que foram aplicados, sobre os quais destacaremos alguns pontos que foram observados ao longo das experimentações.

A população inicial do algoritmo genético, como foi destacada no capítulo anterior, pode ser encontrada de duas maneiras, aleatória ou baseada na curva de carga. Somente depois de uma bateria de testes, verificou-se que a população baseada na curva de carga fornecia melhores resultados.

Ao iniciar o algoritmo genético partindo de população aleatória, verifica-se que todos os indivíduos que formam tal população são em geral inactíveis para o problema. Porém, mesmo partindo de uma população inicial aleatória, para o sistema I, consegue-se em gerações posteriores obter indivíduos factíveis e alcançar boas soluções. Entretanto, para o sistema II, verificou-se através dos testes realizados que o algoritmo não consegue gerar indivíduos factíveis durante boa parte do processo, e na maioria das vezes durante todo o processo de evolução, comprometendo a convergência e a utilização do método quando uma população inicial aleatória é considerada.

No entanto, partindo-se de uma população com base na curva de carga, nem sempre é possível encontrar indivíduos factíveis, porém observa-se que o algoritmo genético geralmente consegue obter indivíduos factíveis após as primeiras gerações. Para permitir o aparecimento de indivíduos factíveis na população inicial, as probabilidades baseadas na curva de carga, que determinam o estado de uma máquina em uma usina (ligado ou desligado), podem ser ajustadas através de um parâmetro. Este parâmetro consiste em um valor variando entre 0 e 1 que deve ser adicionado a probabilidade de estados das máquinas, permitindo que um maior número de máquinas sejam ligadas. Porém, este valor deve ser ajustado com cuidado para não prejudicar a

convergência do método, principalmente quando for considerado o custo de partida e parada das máquinas.

Considerando o Sistema I, verificou-se que é possível encontrar indivíduos factíveis na maioria dos testes sem o uso do parâmetro de ajuste. Porém, para o Sistema II, na maioria dos testes realizados sempre houve a necessidade de se fazer um ajuste nas probabilidades baseadas na curva de carga para encontrar algum indivíduo factível na população inicial ou para garantir o aparecimento de algum ao longo do processo evolutivo. O valor do parâmetro de ajuste das probabilidades utilizado para o Sistema II foi de 0,15.

5.4 Outras considerações

As configurações do algoritmo genético, mostradas na Tabela 5.2, foram estabelecidas após exaustivos testes. Porém, é necessário um estudo mais detalhado, para evidenciar a influência dos parâmetros para uma aplicação desta natureza.

Os resultados apresentados foram encontrados utilizando-se a codificação inteira. Entretanto, neste tipo de problema a codificação binária mostrou-se competitiva. Uma comparação em termos de tempo computacional médio para os dois tipos de codificação, sendo mantida as outras configurações, é estabelecida na Tabela 5.8.

Sistemas	Tempo Computacional (seg)	
	Binária	Inteira
I – Com Custos de Partida e Parada	100	101
I – Sem Custos de Partida e Parada	112	116
II – Com Custos de Partida e Parada	430	374
II – Sem Custos de Partida e Parada	238	404

Tabela 5.8 – Comparação de Tempo Computacional para as Codificações

Através dos dados apresentados na Tabela 5.8, verifica-se que para o Sistema I as codificações apresentam uma diferença muito superficial. Para o Sistema II a codificação binária superou a inteira no caso em que o custo de partida/parada das máquinas é considerado. Porém, a

codificação inteira apresentou melhor desempenho quando o custo de partida/parada é considerado.

O tempo computacional foi obtido com o programa sendo executado em um microcomputador PC com um processador K7 de 700 *MHz*, com 128 *Mb* de RAM.

Os custos das perdas foram calculados considerando-se US\$ 17,045/ *MW* perdido, valor este baseado nos preços de geração de energia fornecida pelo CTEM (Comitê Técnico para Estudos de Mercado) da Eletrobrás.

Os custos de partida e parada consideraram o valor US\$ 3,00/ *MW* instalado, ou seja, o mesmo valor estimado por NILSSON & SJELVGREN (1997b).

5.5 Software desenvolvido

O software desenvolvido para emprego da metodologia foi implementado em linguagem C++, usando o ambiente de programação C++ Builder 5.0.

A seguir, mostra-se através de figuras o software e suas principais atribuições.

A Figura 5.21 apresenta a janela principal do software, onde podem ser feitos os ajustes de usinas, a escolha do algoritmo para encontrar a configuração de máquinas, a determinação do número de execuções do programa, a execução do programa a partir de uma semente pré-definida, e as definições dos custos de partida/parada e dos custos do *MW* gerado e/ou perdido.



Figura 5.21 – Janela Principal

Através da janela principal do software, depois de definido o algoritmo para encontrar a configuração de máquinas, pode-se fazer a configuração do mesmo, bastando selecionar a opção configurar algoritmo no menu arquivo que abrirá a janela apresentada na Figura 5.22. Para este trabalho apenas o algoritmo genético está habilitado, portanto, a janela apresentada refere-se somente a este algoritmo.



Figura 5.22 – Janela de Configuração do Algoritmo Genético

Após a execução do programa pode-se fazer a verificação das principais características do resultado através de várias janelas que podem ser abertas bastando-se selecionar os botões apresentados na janela principal.

A janela apresentada na Figura 5.23 permite a visualização da curva de carga atribuída ao problema.

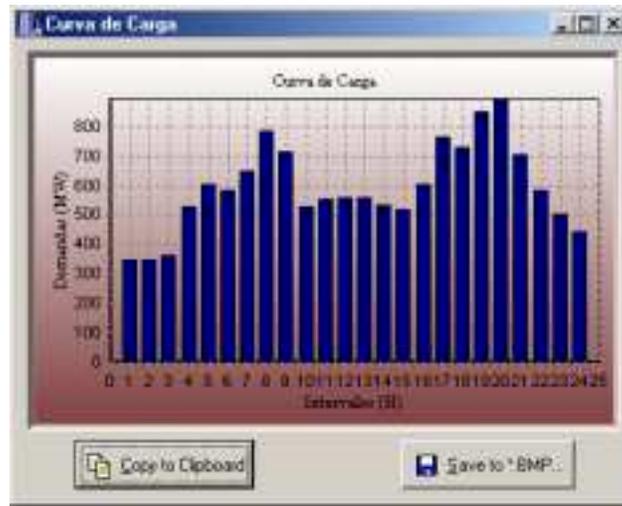


Figura 5.23 – Janela da Curva de Carga

O desempenho do processo evolutivo do Algoritmo Genético pode ser verificado através da janela apresentada na Figura 5.24.

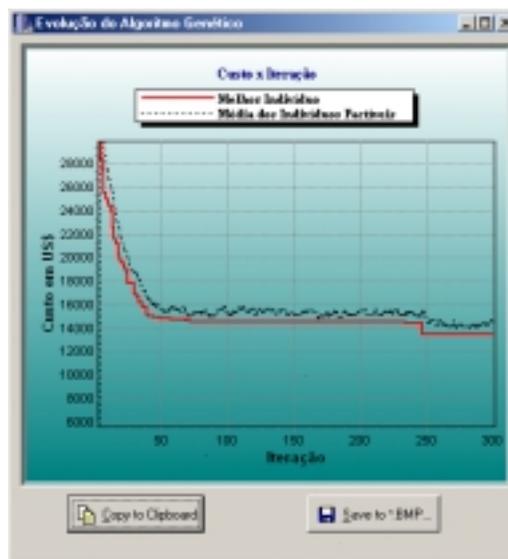
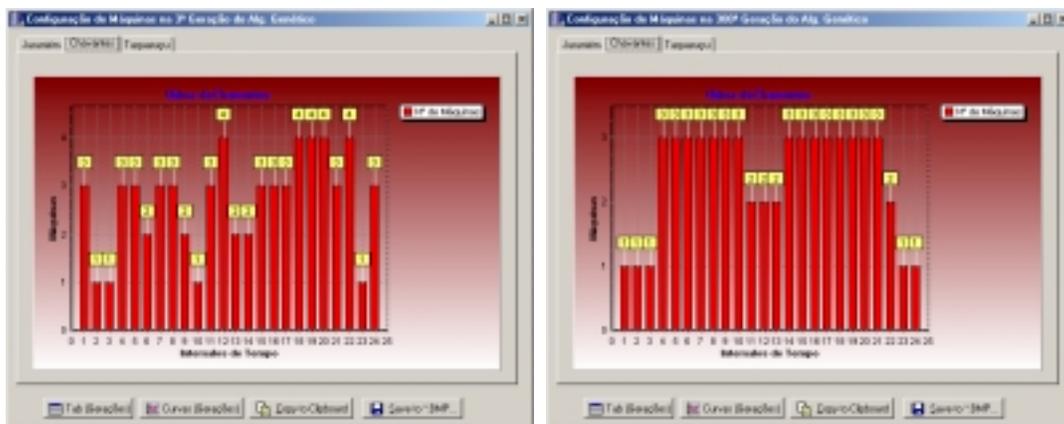


Figura 5.24 – Janela do Desempenho do Algoritmo Genético

A partir da janela apresentada na Figura 5.25, pode-se verificar uma tabela com os resultados encontrados para toda a população inicial e a solução encontrada para cada iteração do algoritmo genético. Selecionando-se qualquer um dos valores na última coluna da tabela, verifica-se o Despacho de Máquinas equivalente a cada iteração do algoritmo genético através de janelas como as apresentadas na Figura 5.26.

POP. INICIAL	Custo Total (US\$)	PERDA (MWh)	GER. DO GA	Custo Total (US\$)	PERDA (MWh)
18	347360.06	100000.000	17	19009.89	657.723
19	345399.98	100000.000	18	19676.24	649.941
20	429022.65	100000.000	19	19652.25	648.533
21	345587.38	100000.000	20	19423.92	652.342
22	606733.82	100000.000	21	19073.00	650.982
23	259595.35	100000.000	22	18782.13	651.123
24	605029.32	100000.000	23	17010.77	650.456
25	347501.64	100000.000	24	17010.77	650.456
26	344547.63	100000.000	25	17010.77	650.456
27	259322.63	100000.000	26	17791.79	648.755
28	519957.73	100000.000	27	17766.65	647.868
29	431221.46	100000.000	28	16926.21	654.882
30	175364.62	100000.000	29	16834.46	649.499
31	429159.01	100000.000	30	16795.11	647.150
32	519736.14	100000.000	31	16702.47	651.699
33	521798.59	100000.000	32	16134.34	636.585
34	693237.20	100000.000	33	16134.34	636.585
35	260021.48	100000.000	34	15825.21	635.654

Figura 5.25 – Janela com Tabela de Resultados do Problema



(a)

(b)

Figura 5.26 – Janelas de Configuração de Máquinas

Para a configuração de máquinas selecionada, pode-se abrir outras duas janelas, uma delas apresenta as curvas (Figura 5.27) e a outra uma tabela de valores (Figura 5.28). As curvas e os valores da tabela referem-se à energia produzida pelas usinas durante o horizonte de estudo.

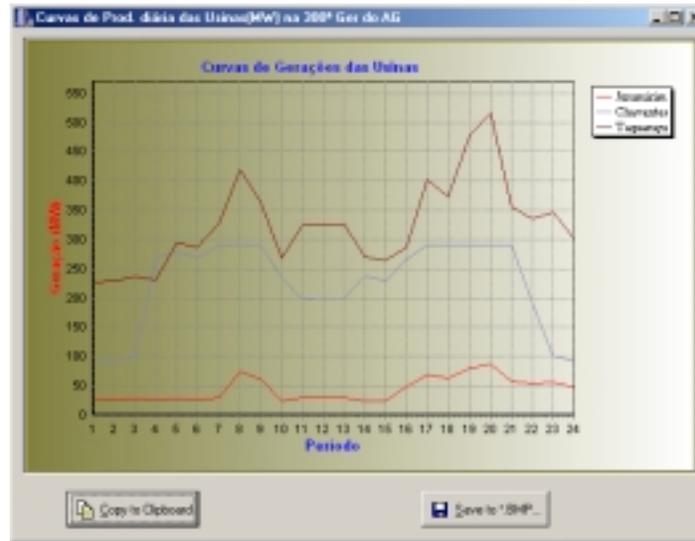


Figura 5.27 – Janela de Curvas de Produção de Energia das Usinas

Período	Itaipu	Chevanlec	Taquaruçu
1	26.016	92.212	227.771
2	26.216	93.412	229.371
3	27.083	98.612	236.305
4	26.495	269.900	231.605
5	27.130	290.053	294.817
6	26.378	268.023	287.599
7	30.531	290.000	327.469
8	74.000	290.000	420.000
9	62.348	290.000	362.652
10	24.273	234.338	267.389
11	30.210	197.402	324.388
12	30.408	199.303	326.289
13	30.408	199.303	326.289
14	24.458	237.947	269.554
15	23.934	228.925	264.141
16	48.315	266.812	296.873
17	69.648	290.000	403.152
18	64.057	290.000	371.933
19	60.676	290.000	478.324

Figura 5.28 – Janela com Tabela de Produção de Energia das Usinas

Capítulo 6

CONCLUSÃO

Este trabalho tratou o problema de pré-despacho em sistema de usinas hidrelétricas, levando em consideração as representações de grupos geradores e custos de partida e parada destas unidades.

Os estudos feitos, aplicados ao Sistema de usinas do rio Paranapanema, evidenciaram as seguintes conclusões (SANTOS *et al.*, 2002):

- O sistema de geração com usinas hidrelétricas possuem perdas significativas que devem ser consideradas no planejamento de curto prazo.
- A inclusão dos custos de partidas e paradas das máquinas influenciam fortemente no despacho de máquinas, e mostrou-se adequada para o controle nas alterações de configuração das máquinas em operação.
- A eficiência dos algoritmos genéticos para descobrir o despacho apropriado de máquinas

Como perspectivas futuras podemos evidenciar os seguintes pontos:

- Considerar máquinas diferentes nas usinas, já que, para cada usina do sistema em que a metodologia foi aplicada, as máquinas são iguais;
- Considerar as perdas associadas ao sincronismo de algumas máquinas que fornecem suporte reativo ao sistema elétrico, quando o mesmo está operando sem carga de potência ativa;
- Aplicar a outros sistemas;

- Aplicar outras ferramentas ao despacho de máquinas, tais como, busca tabu e algoritmos meméticos (CONCILIO, 2000) e comparar os resultados com os encontrados com os algoritmos genéticos.
- Fazer um estudo mais apurado dos operadores genéticos para identificar as dificuldades e tornar possível o desenvolvimento de alguns mais adaptados ao problema e que possam melhorar o programa principalmente no aspecto tempo computacional.

REFERÊNCIAS BIBLIOGRÁFICAS

AARTS, E. & KORST, J. **Simulated Annealing and Boltzmann Machines** – A Stochastic Approach to Combinatorial Optimization and Neural Computing, John Wiley & Sons, 1989;

AMADO, S. M. & RIBEIRO, C. C. Short Term Generation Scheduling of Hydraulic Multi-Reservoir Multi-Area, Interconnected Systems, **IEEE Transactions on Power Systems**, vol. 2, no. 3, pp. 481-486, August 1987;

ARCE, A. S. E. **Um Modelo de Otimização do Despacho de Máquinas em Usinas Hidrelétricas**. 1999. 75f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas;

BÄCK, T., *Evolutionary Algorithms in Theory and Practice*, New York: Oxford University Press, 1996;

BÄCK, T., HAMMEL, U. & SCHWEFEL, H. P. Evolutionary Computation: Comments on the History and Current State, **IEEE Transactions on Evolutionary Computation**, vol. 1, no. 1, pp. 3-17, 1997(a);

BÄCK, T., FOGEL, D. B. & MICHALEWICZ, Z. (eds.) *Handbook Evolutionary Computation*, Oxford University Press, 1997(b);

BÁRDOSSY, A. & DUCKSTEIN, L. *Fuzzy Rule-Based Modeling with Applications to Geophysical, Biological and Engineering Systems*. Boca Raton, FL: CRC, 1995.

BRANNLUND, H., SJELVGREN, D. & BUBENKO, J. A. "Short Term Generation Scheduling with Security Constraints". **IEEE Transactions on Power Systems**, vol. 3, no. 1, pp. 310-316, February 1988;

CHANG, S., CHEN, C., FONG, I. & LUH, P. B. Hydroelectric Generation Scheduling with an Effective Differential Dynamic Programming Algorithm, **IEEE Transactions on Power Systems**, vol. 5, no. 3, pp. 737-743, August 1990;

CHENG, C.-P., LIU, C.-W & LIU, C.-C. Unit commitment by Lagrangian Relaxation and Genetic Algorithms, **IEEE Transactions on Power Systems**, vol. 15, no. 2, pp. 707-714, May 2000;

CONCILIO, R. **Contribuições à Solução de Problemas de Escalonamento pela Aplicação Conjunta de Computação Evolutiva e Otimização com Restrições**. 2000. 121f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas;

EIBEN, Á. E., HINTERDING, R. & MICHALEWICZ, Z. Parameter Control in Evolutionary Algorithms, **IEEE Transactions on Evolutionary Computation**, vol. 3, no. 2, pp. 124-141, July 1999;

ESHELMAN, L. J., CARUANA, R. A. & SCHAFFER, J. D. Biases in Crossover Landscape, in Schafer, J. D. (ed.), *Proceedings of the Third International Conference on Genetic Algorithms*, Morgan Kaufmann Publishers, pp. 2-9, 1989;

FOGEL, L. J., OWENS, A. J. & WALSH, M. J. Artificial intelligence through Simulated Evolution, New York: John Wiley & Sons, Inc., 1966;

FOGEL, D. B. An Introduction to Simulated Evolutionary Computation, **IEEE Transactions on Neural Networks**, vol. 5, no. 1, pp. 3-14, 1994;

FOGEL, D. B. *Evolutionary Computation, Toward a New Philosophy of Machine Intelligence*, New York: IEEE Press, 1995;

FORTUNATO, L. A. M., NETO, T. A. A., ALBUQUERQUE, J. C. R. & FERREIRA, C. **Introdução ao Planejamento da Expansão e Operação de Sistemas de Produção de Energia Elétrica**. Niterói-RJ: Universidade Federal Fluminense, EDDF, 1990. 232p;

GOLDBERG, D. G. *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, 1989;

GLOVER, F. Tabu Search: A tutorial, **Interfaces**, vol.20, no. 4, pp. 74-79, July 1990;

HARA, T. P., VIANNA, L. F. L., NACHVALGER, E. E. & GONCALVES, E. Avaliação do tempo de vida restante das unidades geradoras da usina de GBM e aspectos econômicos. In: *VI Encontro Regional Latino-Americano da Cigré*, 28 de maio a 1 de junho de 1995, CE 39, Foz do Iguaçu – Paraná – Brasil;

HERRERA, F. & LOZANO, M. Adaptive Genetic Operators Based on Coevolution with Fuzzy Behaviors, **IEEE Transactions on Evolutionary Computation**, vol. 5, no. 2, pp. 124-141, April 2001;

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**, 2ª edição, MIT Press, 1992;

IYODA, E. M. **Inteligência Computacional no Projeto Automático de Redes Neurais Híbridas e Redes Neurofuzzy Heterogêneas**. 2000. 166f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas;

KAZARLIS, S. A., BAKIRTZIS, A. G. & PETRIDIS, V. A Genetic Algorithm Solution to the Unit Commitment Problem, **IEEE Transactions on Power Systems**, vol. 11, no. 1, pp. 83-92, February 1996;

LUENBERGER, D. G. Linear and nonlinear programming, 2^a edição, Addison-Wesley, 1989;

LUO, G. X., HABIBOLLAHZADEH, H. & SEMLLIYEN, A. Short Term Generation Hydrothermal Dispatch Detailed Model and solution. **IEEE Transactions on Power Systems**, vol. 4, no. 4, pp. 1452-1462, November 1989;

MAIFELD, T. T. & SHEBLE, G. B. Genetic-Based Unit Commitment Algorithm, **IEEE Transactions on Power Systems**, vol. 11, no. 3, pp. 1359-1370, August 1996;

MICHALEWICZ, Z. Genetic Algorithms + Data Structures = Evolution Programs, 3^a edição, Springer, 1996;

MICHALEWICZ, Z. & SCHOENAEUR, M. Evolutionary Algorithms for Constrained Parameter Optimization Problems, **Evolutionary Computation**, vol. 4, no. 1, 1996, pp. 1-32;

NILSSON, O. & SJELVGREN, D. Hydro unit start-up and their impact on the short term scheduling strategies of Swedish power producers, **IEEE Transactions on Power Systems**, vol. 12, no. 1, pp. 38-43, February 1997(a);

NILSSON, O. & SJELVGREN, D. Variable splitting applied to modeling of start-up costs in short term hydro generation scheduling, **IEEE Transactions on Power Systems**, vol. 12, no. 2, pp. 38-43, May 1997(b);

OHISHI, T., SOARES, S. & CARVALHO, M. F. Short Term Generation Hydrothermal Scheduling Approach for Dominantly Hydro Systems, **IEEE Transactions on Power Systems**, vol. 6, no. 2, pp. 637-643, May 1991;

PEDRYCZ, W. & GOMIDE, F. An Introduction to Fuzzy Sets: Analysis and Design, MIT Press, Cambridge, MA, 1998;

RECHENBERG, I. Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution, Frommann-Holzboog, 1973;

SANTOS, E. F., MELLO, O. D., & OHISHI, T. A Predispach Model of Hydroelectric Power Systems using Genetic Algorithms, artigo aceito pelo: *VIII Symposium of Specialists in Electric Operational and Expansion Planning*, a ser realizado de 19 a 23 de Maio de 2002, Brasília-DF;

SCHWEFEL, H. -P. Evolution and Optimum Seeking, Sixth-Generation Computer Technology Series, Wiley, 1995;

SHEBLE, G. B. & FAHD, G. N. Unit Commitment Literature Synopsis, **IEEE Transactions on Power Systems**, vol. 9, no. 1, pp. 128-136, February 1994;

SILVA, A. C., **Otimização do Transporte em Oleodutos Utilizando Algoritmos Genéticos e Programação Linear**. 1999. 85f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas;

SOARES, S. & OHISHI, T. **Operação Econômica de Sistemas Hidrotérmicos**. CEAPO, Módulo 7, Universidade Estadual de Campinas, 1989;

SOARES, S. & SALMAZO, C., Minimum Loss Predispach Model for Hydroelectric Power Systems, **IEEE Transactions on Power Systems**, vol. 12, no. 3, pp. 38-43, August 1997;

SYSWERDA, G. Uniform Crossover in Genetic Algorithms, em Schafer, J. D. (ed.), *Proceedings of the Third International Conference on Genetic Algorithms*, Morgan Kaufmann Publishers, pp. 2-9, 1989;

ZHUANG, F. & GALIANA, F. D. Towards a more Rigorous and Practical Unit Commitment by Lagrangian Relaxation, **IEEE Transactions on PWRs-3**, no. 2, pp. 763-773, May 1988.

Índice Remissivo de Autores

Aarts & Korst, 1989	29
Amado & Ribeiro, 1987.....	2
Arce, 1999.....	1, 2, 8, 19
Bäck, 1996.....	28
Bäck, Hammel & Schwefel, 1999.....	37
Bäck, Fogel & Michalewicz, 1997.....	47
Bárdossy & Duckstein, 1995.....	40
Brannlund, Sjelvgren & Bubenko, 1988.....	2
Chang, Chen, Fong & Luh, 1990.....	2
Cheng, Liu & Liu, 2000.....	3
Concilio, 2000.....	80
Eiben <i>et al.</i> , 1999.....	40
Eshelman, Caruana & Schaffer, 1989.....	34
Fogel, Owens & Walsh, 1966.....	28
Fogel, 1994.....	37
Fogel, 1995.....	27
Fortunato <i>et al.</i> , 1990.....	8
Goldberg, 1989.....	36
Glover, 1990.....	29
Hara <i>et al.</i> , 1995.....	19
Herrera & Lozano, 2001.....	40
Holland, 1992	27, 28, 31, 33, 36
Iyoda, 2000.....	26, 29
Kazarlis, Bakirtzis & Petridis, 1996.....	3
Luenberger, 1989.....	42, 51, 52
Luo, Habibollahzadeh & Semliyen, 1989.....	2
Maifeld & Sheble, 1996.....	3

Michalewicz, 1996	29, 30, 31, 35, 36, 37
Michalewicz & Schoenaer, 1996.....	35, 36
Nilsson & Sjelvgren, 1997(a).....	19
Nilsson & Sjelvgren, 1997(b).....	1, 19, 20, 74
Ohishi, Soares & Carvalho, 1991.....	2
Pedrycz & Gomide, 1998.....	40
Rechenberg, 1973.....	27
Santos, Mello & Ohishi, 2002.....	79
Schwefel, 1995.....	27
Sheble & Fahd, 1994.....	24
Silva, 1999.....	32
Soares & Ohishi, 1989.....	7
Soares & Salmazo, 1997.....	2
Syswerda, 1989.....	34
Zhuang & Galiana, 1988.....	2