

Centro de Pesquisas de Energia Elétrica - CEPEL



Relatório Técnico

Nº/Ano: 27628/2017 **Nº de Páginas:** 53 **Nº de Anexos:**

Título: Utilização de Algoritmos Genéticos para a Determinação de uma Configuração Alternativa para as Faixas Operativas Empregadas pelo Modelo SUISHI

Departamento: Departamento de Otimização Energética e Meio Ambiente - DEA

Área de Responsabilidade: B200 **Conta de Apropriação:** 1311

Cliente: Às Centrais Elétricas Brasileiras S/A - ELETROBRAS Av. Presidente Vargas, 409, Rio de Janeiro / RJ	Equipe de acompanhamento: Jhonatan Ross - DGEP - ELETROBRAS Flávio Cardinot - ELETROBRAS
Atenção: Márcio Antônio Guedes Drummond	

Resumo:
O presente relatório apresenta a utilização da meta-heurística conhecida como Algoritmos Genéticos com o objetivo de investigar a existência de configurações de faixas operativas alternativas à configuração padrão adotada pelo modelo SUISHI para os reservatórios das usinas hidroelétricas, de tal forma que o custo de operação do sistema ao longo do horizonte de planejamento possa ser reduzido.

Autores:
Fabio Rodrigo Siqueira Batista - Cepel
Luiz Guilherme Barbosa Marzano - Cepel
Maria Elvira Piñeiro Maceira - Cepel

Palavras-Chave:
Algoritmo Genético
Faixas Operativas de Reservatórios de UHes
Simulação a Usinas Individualizadas

Classificação: CONTROLADO

Gerente de Projeto

Fabio Rodrigo Siqueira Batista
Tel.: 2598-6376 **Fax:** 2598-6482
E-mail: fabrsb@cepel.br

Chefe do Departamento de Otimização Energética e Meio Ambiente

André Luiz Diniz Souto Lima
Tel.: 2598-6046 **Fax:** 2598-6482
E-mail: diniz@cepel.br

Aprovação

Raul Balbi Söllero
Diretor de Pesquisa, Desenvolvimento e Inovação
27/12/17

**UTILIZAÇÃO DE ALGORITMOS GENÉTICOS PARA A
DETERMINAÇÃO DE UMA CONFIGURAÇÃO ALTERNATIVA
PARA AS FAIXAS OPERATIVAS EMPREGADAS NO MODELO
SUISHI**

Sumário

1.	Introdução.....	4
2.	Revisão Bibliográfica	7
3.	O Modelo Suishi	9
4.	Algoritmos Genéticos.....	14
4.1.	Representação de Cromossomos.....	15
4.2.	Função de Aptidão	18
4.3.	População	19
4.4.	Método de Seleção de Pais	23
4.5.	Operadores Genéticos	24
4.6.	Critério de convergência	26
5.	Abordagem Metodológica do Problema.....	27
6.	Resultados.....	29
6.1.	Análises de Convergência e Melhor Solução.....	29
6.2.	Resultados Subsistema Único	38
6.3.	Resultados com 4 Subsistemas	42
7.	Conclusões.....	50
8.	Bibliografia	52

1. Introdução

No Sistema Elétrico Brasileiro há participação majoritária da hidroeletricidade no atendimento ao consumo de energia elétrica. As usinas hidroelétricas que compõem o parque gerador nacional estão localizadas ao longo de cascatas em bacias hidrográficas com comportamentos hidrológicos distintos. Ademais, há várias usinas que possuem capacidade de regularização plurianual. Sendo assim, para viabilizar o trabalho do planejador, uma cadeia de modelos computacionais foi desenvolvida pelo CEPEL [1], a qual racionaliza a utilização dos recursos computacionais dividindo o estudo em diversos horizontes temporais. Por exemplo, os estudos relativos ao planejamento da operação energética inclui desde modelos de médio e longo prazo, com horizontes variando de 5 a 10 anos e discretização mensal, até modelos para a realização da programação diária da operação, determinada em base horária.

Um dos objetivos do planejamento da operação do sistema hidrotérmico brasileiro é determinar uma operação estratégica que, para cada período do planejamento, produza metas de geração para as usinas do sistema de forma a minimizar o custo total de operação ao longo de todo o horizonte de planejamento. Neste contexto, o modelo computacional oficialmente empregado no Brasil para a realização do planejamento da operação energética de médio prazo é o modelo NEWAVE [2]. Entre as principais características deste modelo destacam-se: (i) representação detalhada da incerteza associada às vazões naturais afluentes às usinas hidroelétricas; (ii) o agrupamento das usinas hidroelétricas de um mesmo subsistema em reservatórios equivalentes de energia; e (iii) adoção da programação dinâmica dual estocástica como algoritmo de solução. Os reservatórios equivalentes são interligados eletricamente, representando os grandes troncos de linhas de transmissão entre os diversos subsistemas elétricos do sistema brasileiro [2].

Um dos resultados disponibilizados pelo modelo NEWAVE são as metas de geração hidroelétricas por subsistema equivalente, para até 2000 cenários de aflúncias às usinas. Uma vez que os resultados do NEWAVE são determinados a subsistemas equivalentes de energia, as metas de geração individualizadas podem ser obtidas por outro modelo da cadeia, o modelo SUIISHI [1][3], o qual é caracterizado como um modelo de médio prazo para a simulação da geração das usinas hidroelétricas individualizadas que operam em um sistema hidrotérmico interligado, tal como o sistema brasileiro.

Ao simular a operação das usinas hidroelétricas do sistema, o modelo SUIISHI utiliza regras heurísticas que tentam emular as práticas operativas adotadas no Sistema Interligado Nacional. Uma das premissas adotadas pelo SUIISHI é a de operar os reservatórios de cada subsistema procurando enchê-los/deplecioná-los de modo que seus níveis percentuais de armazenamento sejam idênticos. Para tanto, atualmente considera-se que cada reservatório é dividido em 20 faixas operativas, cada qual representando 5% do seu respectivo volume útil. Ao longo deste relatório tal configuração será denominada por *configuração default*.

Tendo em vista o exposto anteriormente, observa-se que a amplitude das faixas operativas pode ter influência na qualidade dos resultados do modelo SUIISHI, uma vez que elas orientam o processo de simulação da operação dos reservatórios das usinas hidrelétricas. Sendo assim, coloca-se como o objetivo dos estudos apresentados neste relatório a utilização da meta-heurística conhecida como Algoritmos Genéticos [4] para investigar a existência de configurações de faixas operativas alternativas à *configuração default*, de tal forma que o custo de operação do sistema ao longo do horizonte de planejamento possa ser reduzido.

Na próxima seção é apresentada uma revisão bibliográfica sobre a utilização dos algoritmos genéticos em problemas associados ao planejamento da operação energética de sistemas elétricos em geral. Na seção 3 são

descritas as principais características do processo de solução empregado pelo modelo SUIHI para a obtenção da geração hidráulica individualizada ao longo do horizonte de planejamento. Tal descrição é importante pois auxiliará a compreensão do problema que se pretende resolver. Na seção 4 serão descritos os principais conceitos associados aos AG, e como tais conceitos se encaixam no escopo deste trabalho. Na seção 5 apresenta-se em detalhes o algoritmo de solução empregado neste trabalho. Os resultados obtidos são apresentados na seção 6. Finalmente, a seção 7 traz as conclusões deste trabalho.

Ressalta-se que este relatório é baseado no trabalho de projeto de graduação de Guilherme Araújo Rosa, desenvolvido sob orientação do pesquisador do CEPEL Fabio Rodrigo Siqueira Batista e da professora Carmen Lúcia Tancredo Borges, submetido ao corpo docente do Departamento de Engenharia Elétrica da Escola Politécnica da Universidade Federal do Rio de Janeiro em agosto de 2013, com parte dos requisitos necessários para a obtenção do grau de engenheiro eletricista.

2. Revisão Bibliográfica

A meta heurística atualmente conhecida como Algoritmos Genéticos (AG) surgiu na década de 1970, mencionada por John Holland [4] em 1975, e, desde então, tem sido empregada na busca de soluções ótimas, ou sub-ótimas, para os mais diversos problemas de otimização. Por exemplo, os AGs têm sido frequentemente utilizados em problemas da indústria do Petróleo e Gás (vide Montesinos [5] e Gavancho et al [6]), na engenharia financeira (vide Lazo [7]), entre outros.

No que tange à problemas associados ao planejamento da operação energética de sistemas elétricos, a aplicação dos AG também tem sido bastante variada. Por exemplo, Orero & Irving [8] aplicam algoritmos genéticos para a determinação do despacho ótimo horário das usinas de um sistema hidrotérmico, levando em consideração a relação não linear entre a vazão defluente, a altura de queda líquida e a geração de energia das usinas hidráulicas do sistema. As defluências das usinas hidroelétricas foram consideradas como variáveis de controle neste problema. O AG foi utilizado a partir da geração de uma população de possíveis defluências para as usinas hidroelétricas, sendo executado até que uma solução ótima fosse encontrada.

Outras aplicações ao mesmo tipo de problema são as descritas por Kumar et al [9] e Zoumas et al [10], os quais aplicam AG para a determinação do despacho hidrotérmico de curto prazo. Vale ressaltar que no trabalho de Kumar et al [9] também são estudados aprimoramentos para a aceleração do processo de convergência do AG. A solução é aplicada a sistemas teste, e a avaliação das soluções é feita pela eficiência do uso de recursos computacionais disponíveis. Já Zoumas et al [10] aborda o problema de coordenação hidrotérmica do sistema grego utilizando algoritmos genéticos. As variáveis de controle deste problema são as defluências por máquina e o seu *status*, ligado ou desligado, considerando todas as usinas hidroelétricas do sistema. As possíveis soluções geradas pelo AG respeitam as restrições de defluências máxima e mínima, sendo que a qualidade de cada possível solução

é determinada pela razão entre o custo de operação do sistema, considerando o atendimento ao mercado apenas com usinas térmicas, e o mesmo custo determinado quando o mercado é atendido pelo parque hidrotérmico.

As aplicações dos AGs ao planejamento da operação hidrotérmica do sistema elétrico brasileiro também são diversas, destacando-se nesta seção os trabalhos de Ferreira & Silva [11] e Leite et al [12]. Ferreira & Silva [11] utilizam dois sistemas (teste) hidrotérmicos, que fazem parte do sistema elétrico brasileiro, para comparar a utilização das técnicas de *Algoritmo Genético* e de *Arrefecimento Simulado* ao problema do planejamento do despacho de sistemas hidrotérmicos. Já o trabalho de Leite et al [12] investiga a aplicação de *Algoritmos Genéticos* ao planejamento de médio-prazo (até 2 anos). Os autores deste trabalho tomam como variáveis de controle o nível dos reservatórios em cada estágio do problema. A abordagem adotada apresentou resultados melhores do que a aplicação de técnicas de programação não linear (algoritmo de fluxo de rede não-linear).

Como pode ser observado, existem diversos trabalhos envolvendo a aplicação de *Algoritmos Genéticos* ao planejamento da operação de sistemas hidrotérmicos, tal como o sistema brasileiro. Entretanto, nestes casos, a utilização do AG tem por objetivo a definição do despacho das usinas do sistema, o que difere do escopo deste trabalho. O trabalho apresentado neste relatório tem por objetivo a utilização dos AGs como ferramenta de suporte às metodologias e modelos computacionais empregados no planejamento da operação energética do sistema interligado nacional, aprimorando os parâmetros que alimentam a aplicação de tais modelos, em particular do modelo SUISHI.

3. O Modelo Suishi

Tal como mencionado na seção 1, um dos objetivos do planejamento da operação do sistema hidrotérmico brasileiro é determinar uma operação estratégica que, para cada período do horizonte de planejamento, produza metas de geração para as usinas do sistema de forma a minimizar o custo total de operação ao longo deste período. No Brasil, tal planejamento é oficialmente realizado por meio da utilização do modelo NEWAVE, o qual, além de uma política para a operação do sistema, também disponibiliza metas de geração hidroelétrica para cada reservatório equivalente considerado.

Uma vez que os resultados do NEWAVE são determinados por reservatório equivalente de energia, pode ser necessária a obtenção de metas de geração individualizadas por usina hidroelétrica. Neste contexto, o modelo SUIHI surge como um modelo de médio prazo para a simulação da operação das usinas hidrelétricas individualizadas¹.

O processo de solução adotado pelo modelo SUIHI é dividido em duas etapas. A primeira etapa consiste na otimização do balanço hidrotérmico entre subsistemas equivalentes, o que, a rigor, equivale ao problema resolvido pelo modelo NEWAVE durante a simulação final da operação do sistema (para maiores detalhes vide Maceira et al [2]). Nesta etapa, o objetivo do modelo SUIHI é, com base na política de operação definida pelo modelo NEWAVE, definir metas de geração hidráulica a subsistemas equivalentes, metas de geração térmica, e os intercâmbios de energia que minimizem a soma do custo presente com o custo futuro ao longo de todo o horizonte de planejamento.

Já na segunda etapa, as metas de geração hidráulica pré-determinadas a subsistemas equivalentes, alimentam o módulo de simulação a usinas

¹ As principais aplicações do modelo SUIHI estão voltadas para os estudos de planejamento energético, tais como o cálculo de energia firme, subsídios para a elaboração de casos de referência para estudos de planejamento elétrico, estudos de viabilidade de usinas hidrelétricas, estudos de estratégias de comercialização da energia gerada por usinas hidroelétricas, entre outras.

individualizadas do modelo SUIHI. O objetivo desta etapa é alocar as metas de geração hidráulica de cada subsistema entre as usinas hidrelétricas através da aplicação de regras heurísticas operativas, procedimento este que é denominado de simulação da operação.

Note que ao final da etapa de simulação, duas distintas situações podem ser observadas:

(i) o atendimento das metas de geração hidráulica previamente definidas na etapa de otimização do balanço hidrotérmico. Neste caso o modelo passa para o próximo estágio do problema; ou

(ii) o não atendimento das metas de geração hidráulica ocasionado por um déficit ou um excesso na soma da geração hidráulica individualizada².

Nestes casos, o modelo SUIHI irá realimentar a etapa de otimização do balanço hidrotérmico entre subsistemas redefinindo, em cada subsistema onde foi observado um déficit de geração, a sua restrição de geração hidráulica máxima (GHMAX), e/ou, em cada subsistema onde foi observado um excesso de geração, a sua restrição de energia armazenada máxima (EARMAX), de tal forma que as metas de geração hidráulica a subsistema equivalente possam ser atendidas na segunda etapa do processo de solução.

A Figura 1 apresenta um fluxograma do processo de solução do modelo SUIHI. É importante ressaltar que, dentre outros fatores, o processo de simulação da operação a usinas individualizadas é baseado principalmente em:

- (i) divisão dos reservatórios em faixas operativas;
- (ii) manutenção da faixa superior dos reservatórios livre para aumentar a capacidade de armazenamento do excesso de afluentes durante o período úmido, minimizando-se os vertimentos e as inundações a jusante;

² Quando as vazões afluentes se acham mal distribuídas com relação ao estado de armazenamento dos reservatórios, pode ser impossível armazenar toda a água excedente, ocorrendo então os chamados vertimentos turbináveis ou excessos de geração. Por outro lado, ao se levar em conta as limitações de turbinamento das usinas do subsistema, é possível que a meta de geração hidráulica do subsistema seja inatingível a usinas individualizadas, o que caracteriza um déficit de geração hidráulica.

(iii) manutenção da faixa inferior dos reservatórios cheia para evitar uma excessiva perda de potência no sistema devido à redução das alturas de queda líquida;

(iv) manutenção de todos os reservatórios do sistema, tanto quanto possível, dentro de uma mesma faixa operativa, e;

(v) estabelecimento de prioridades para o enchimento e o esvaziamento dos reservatórios que se encontram na mesma faixa operativa. Tais prioridades são baseadas nas produtibilidades acumuladas de cada usina hidroelétrica do subsistema, sendo que, as usinas com elevada produtividade acumulada possuem prioridade de esvaziamento frente às usinas com baixa produtividade acumulada. Por outro lado, as usinas com baixa produtividade acumulada possuem prioridade de enchimento frente às usinas com alta produtividade acumulada.

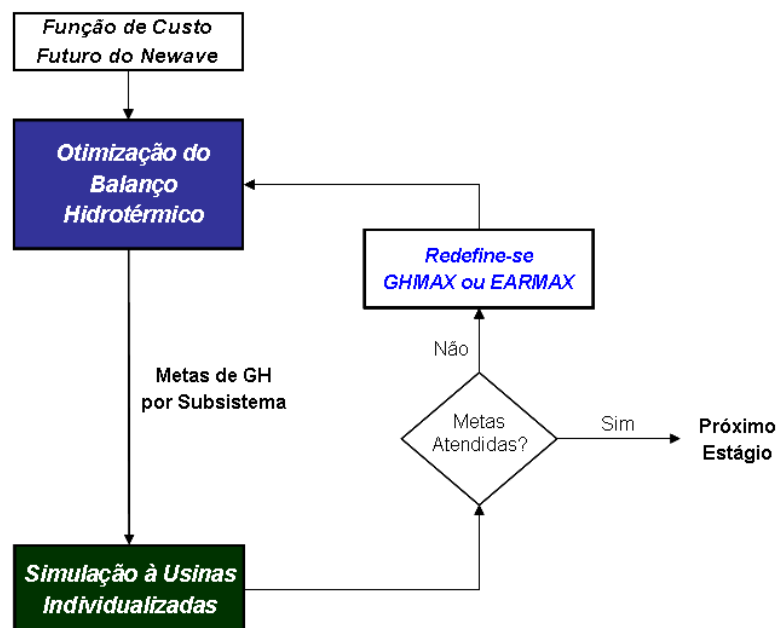


Figura 1- Fluxograma de funcionamento do modelo SUIHI

Em resumo, o processo de simulação da operação do modelo SUIHI segue dois critérios hierárquicos: primeiro procura-se equilibrar os volumes dos reservatórios em uma mesma faixa operativa; para, posteriormente, dentro de

cada faixa, percorrer os reservatórios de acordo com a sua prioridade de enchimento/esvaziamento.

Atualmente, a configuração *default* adotada no modelo divide cada reservatório do sistema em 20 faixas operativas, as quais representam 5% do seu volume útil, tal como ilustrado na Figura 2.

Destaca-se que o modelo SUIISHI permite ao usuário a determinação da amplitude de cada uma das faixas operativas representadas nas usinas hidrelétricas com reservatórios do sistema. Uma vez que a determinação das faixas operativas são necessárias para a simulação da operação a usinas individualizadas, nota-se que a sua amplitude pode influenciar a qualidade dos resultados obtidos.




Figura 2 - Representação gráfica das faixas operativas de um reservatório

Nesse sentido, entende-se que é importante avaliar outras possibilidades de amplitudes para as faixas operativas de cada usina. Uma possibilidade é definir faixas operativas que acentuem ainda mais o deplecionamento dos reservatórios de montante (que possuem maior produtividade acumulada), de tal forma que a maior vazão turbinada nestas usinas possa ser aproveitada nas usinas à jusante na cascata. Sendo assim,

coloca-se como o objetivo dos estudos apresentados neste relatório a utilização da meta-heurística conhecida como Algoritmos Genéticos para investigar a existência de configurações de faixas operativas alternativas à atualmente empregada pelo modelo SUIISHI.

4. Algoritmos Genéticos

Os algoritmos genéticos (AGs), propostos na década de 1970 por John Holland [4] são um ramo dos algoritmos evolucionários e podem ser definidos como uma técnica de busca baseada numa metáfora do processo biológico de evolução natural [13].

Consoante a teoria da seleção natural de Darwin, sabemos que os indivíduos mais aptos à sobrevivência dentro de uma população tendem a propagar essas características para gerações futuras, enquanto que as características daqueles menos aptos tendem a desaparecer com o tempo. Os AGs funcionam baseados nessa premissa.

Dentre as principais vantagens dos AGs, destaca-se o fato do mesmo ser caracterizado como uma heurística global e não utilizar informações locais, tais como derivadas e gradientes para a realização da busca. Esta característica lhe confere a condição de não se prender a ótimos locais, podendo ainda ser aplicado a funções descontínuas ou discretas sem queda de desempenho. Outra importante vantagem dos AGs é o seu paralelismo, ou seja, as soluções obtidas para uma população de indivíduos podem ser avaliadas simultaneamente, o que possibilita uma redução do custo computacional na utilização do algoritmo.

De maneira geral, pode-se dizer que a aplicação dos AGs passa pela seguinte seqüência de procedimentos:

- (i) inicialmente é necessário a criação de uma população inicial contendo possíveis soluções do problema a ser resolvido;
- (ii) todas as soluções dentro dessa população são avaliadas segundo um critério pré-estabelecido, que define uma escala de valor para as soluções encontradas, ou seja, subsidia a sua classificação da melhor à pior solução;
- (iii) também segundo um critério pré-estabelecido, as elementos da população atual são combinadas de forma a gerar uma nova população;

(iv) a nova população é então avaliada e os critérios de convergência são testados. Caso estes critérios sejam atendidos, o processo é encerrado. Caso contrário, retorna-se ao passo (iii) e o AG é executado até a sua convergência.

Tendo em vista a sequência anteriormente descrita, nota-se que alguns aspectos são fundamentais na utilização dos algoritmos genéticos, entre eles a forma utilizada para representar a solução do problema, o critério de avaliação das soluções encontradas, além do método utilizado para combinar estas soluções de forma a se obter uma nova população de indivíduos. Obviamente, espera-se que quanto maior o espaço de busca do AG maior será a qualidade da solução encontrada. Por exemplo, se todo o espaço de soluções do problema for avaliado, a melhor solução encontrada será a solução ótima.

Também cabe destacar que a terminologia empregada pelos AGs possui uma forte analogia com a biologia. Por exemplo, uma possível solução do problema (um indivíduo da população) é usualmente denominado por *cromossomo*. Uma parte do *cromossomo*, que por sua vez representa uma característica do mesmo, pode ser denominado como um *gene*, o valor do *gene* é chamado de *alelo*, e a sua posição é denominado *locus*.

Finalmente, vale ressaltar que as possíveis soluções do problema são avaliadas por meio das "Funções de Aptidão", enquanto que as combinações das melhores soluções se dará mediante a "Seleção de Pais" (soluções a serem combinadas) e a aplicação de "Operadores Genéticos" para a combinação dos mesmos. Estes processos serão detalhadamente descritos a seguir, onde também será feita uma analogia de tais processos com o objeto de estudo no presente relatório.

4.1. Representação de Cromossomos

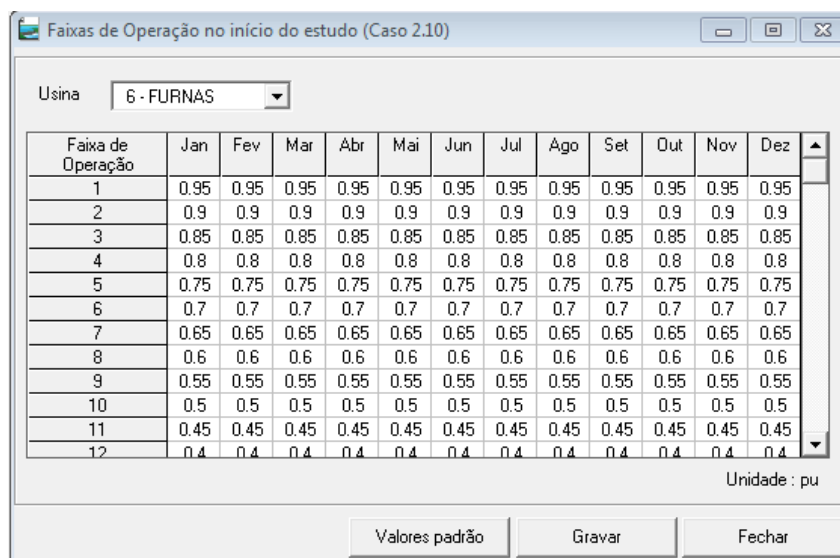
A representação dos cromossomos é fundamental para a execução do algoritmo genético, pois ela codifica a informação do problema de forma que ela possa ser tratada computacionalmente.

Qualquer estrutura de dados pode ser utilizada para a representação de cromossomos, porém, as mais comuns são:

- Estrutura Binária;
- Números Inteiros; e
- Números Reais.

Ao determinar a representação do cromossomo é importante ter em mente que os cromossomos precisarão ser combinados. Logo, quanto mais simples for a representação, mais fácil será o desenvolvimento dos operadores responsáveis pelas combinações.

Tal como dito na seção 3, para simular a operação das usinas hidroelétricas individualizadas, o modelo SUIHI considera que cada reservatório do sistema é dividido em 20 faixas operativas, cada qual representando 5% do seu respectivo volume útil (Vide Figura 3).



Faixa de Operação	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.95
2	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
3	0.85	0.85	0.85	0.85	0.85	0.85	0.85	0.85	0.85	0.85	0.85	0.85
4	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8
5	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75
6	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
7	0.65	0.65	0.65	0.65	0.65	0.65	0.65	0.65	0.65	0.65	0.65	0.65
8	0.6	0.6	0.6	0.6	0.6	0.6	0.6	0.6	0.6	0.6	0.6	0.6
9	0.55	0.55	0.55	0.55	0.55	0.55	0.55	0.55	0.55	0.55	0.55	0.55
10	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5
11	0.45	0.45	0.45	0.45	0.45	0.45	0.45	0.45	0.45	0.45	0.45	0.45
12	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4

Figura 3 - Janela da interface gráfica do modelo SUIHI para a configuração das faixas operativas de uma usina hidroelétrica

Considerando que esta configuração representa um indivíduo do espaço de possíveis soluções, ou seja, é uma das soluções candidatas a minimizar o

custo total de operação determinado pelo modelo, pode-se definir a representação deste cromossomo (ou um indivíduo da população) tal como ilustrado na Figura 4. Nesta figura, note que a matriz possui 20 linhas, cada qual representando o número de faixas operativas adotadas em cada usina, e NUS colunas, cada qual representando o número de usinas hidroelétricas com reservatório do sistema.

$$\begin{bmatrix}
 95\% & 95\% & K & 95\% & 95\% \\
 90\% & 90\% & \Lambda & 90\% & 90\% \\
 85\% & 85\% & \Lambda & 85\% & 85\% \\
 M & M & M & M & M \\
 10\% & 10\% & \Lambda & 10\% & 10\% \\
 5\% & 5\% & \Lambda & 5\% & 5\% \\
 0\% & 0\% & \Lambda & 0\% & 0\%
 \end{bmatrix}_{20 \times NUS}$$

Figura 4 – Representação do cromossomo para a configuração *Default* do SUIISHI

O processo de solução adotado passará pela avaliação de diversos outros cromossomos até se chegar a solução do problema. De maneira geral, tais cromossomos podem ser representados de forma análoga a anterior, ou seja:

$$\begin{bmatrix}
 f_{1,1} & f_{1,2} & K & f_{1,(NUS1)} & f_{1,NUS} \\
 f_{2,1} & f_{2,2} & K & f_{2,(NUS1)} & f_{2,NUS} \\
 f_{3,1} & f_{3,2} & K & f_{3,(NUS1)} & f_{3,NUS} \\
 M & M & M & M & M \\
 f_{18,1} & f_{18,2} & K & f_{18,(NUS1)} & f_{18,NUS} \\
 f_{19,1} & f_{19,2} & K & f_{19,(NUS1)} & f_{19,NUS} \\
 f_{20,1} & f_{20,2} & K & f_{20,(NUS1)} & f_{20,NUS}
 \end{bmatrix}_{20 \times NUS}$$

Figura 5 – Representação geral de um cromossomo para o problema estudado

Na Figura 5 $f_{i,j}$ representa o limite inferior da i -ésima faixa operativa da j -ésima usina hidroelétrica com reservatório da configuração³. Note que não é um dos objetivos deste trabalho avaliar o número de faixas operativas utilizadas, o qual será mantido fixo em 20, mas sim a amplitude de tais faixas empregadas a cada usina. No caso particular do estudo de caso a ser descrito na seção 6, foram consideradas 71 usinas hidroelétricas com reservatório.

Seguindo as definições descritas no início desta seção, note que as faixas operativas de uma única usina da configuração representa uma característica do cromossomo, ou seja, um *gene* do mesmo. Finalmente, para este caso em particular, um gene do cromossomo pode assumir qualquer seqüência em ordem decrescente de números contidos no intervalo $[0; 0,999]$. Esse ordenamento é necessário, pois, considerando duas faixas adjacentes, a faixa operativa mais abaixo (por exemplo a faixa **i**) não pode ter um limite inferior maior do que o limite inferior da faixa acima (faixa **i-1**), caso contrário uma mesma zona do reservatório estaria inclusa em duas faixas diferentes.

4.2. Função de Aptidão

A função de aptidão é o mecanismo utilizado para se determinar a qualidade de uma solução. Essa função utiliza os parâmetros armazenados no cromossomo e retorna um valor numérico que indica a qualidade da solução utilizando esses parâmetros.

A função de aptidão deve conter o maior conhecimento possível acerca do problema, seus objetivos e restrições, e, se possível, diferenciar soluções “sub-ótimas”. É interessante adotar funções de aptidão que tenham contradomínio estritamente positivo para facilitar o funcionamento do processo de seleção.

³ Apesar do modelo SUSHI permitir a variação das faixas operativas de uma determinada usina hidroelétrica ao longo do horizonte de planejamento, tal variação foi desconsiderada neste trabalho a fim de reduzir o espaço de soluções.

Neste trabalho, note que o modelo SUIHI é estudado como uma ferramenta para a realização/auxílio do planejamento da operação energética de médio/longo prazo em sistemas hidrotérmicos interligados. Como tal, diferentes resultados (em base mensal), por subsistema, são obtidos a partir da execução do modelo, entre eles os seguintes:

- Energia Armazenada Final;
- Custo Marginal de Operação;
- Geração Hidráulica Total;
- Energia Vertida;
- Déficit e Excesso de Geração; e
- Custo Total da Operação.

Uma vez que o objetivo do planejamento da operação é minimizar o valor esperado do custo total de operação do sistema, assumiu-se como premissa que a solução de mínimo custo levará aos valores ótimos de armazenamento, geração hidráulica e demais parâmetros do sistema. Por este motivo, adotou-se neste trabalho o custo de operação médio mensal como a função de aptidão empregada pelo AG, ou seja:

$$FA_c = \frac{\sum_{s=1}^{NSER} \sum_{m=1}^{NMES} CUSTO_{c,s,m}}{NSER \times NMES} \quad (1)$$

onde FA_c representa a função de aptidão de um determinado cromossomo c , $CUSTO_{c,s,m}$ representa o custo de operação (inclui geração térmica e déficit de energia) obtido para um determinado cromossomo c , em um determinado mês m de uma determinada série hidrológica s , $NSER$ representa o número de séries hidrológicas consideradas, e $NMES$ o número de meses do horizonte de planejamento.

4.3. População

Na maioria dos trabalhos que utilizam algoritmo genético, a população é inicializada aleatoriamente devido à sua maior simplicidade, também

esperando-se que os indivíduos estejam bem distribuídos pelo espaço de soluções, ou seja, sem um padrão pré-definido.

O tamanho da população é determinante na execução do algoritmo genético. Caso a população seja muito pequena, não haverá variabilidade genética suficiente para que se alcancem boas soluções, pois as soluções podem não cobrir de maneira satisfatória o espaço. Caso a população seja muito grande, o algoritmo genético aproximar-se-á de uma busca exaustiva demandando um esforço computacional muito grande.

Obviamente, o tamanho ideal da população depende do tamanho do espaço de soluções e dos operadores genéticos utilizados. Normalmente, são necessárias várias execuções com tamanhos de população diferentes, de forma a calibrar o algoritmo genético. O número 100 é visto com grande frequência em trabalhos, mas não é necessariamente ótimo.

Neste trabalho será realizada uma análise de sensibilidade com relação ao tamanho da população. Por se tratar de um problema com um grande espaço de possíveis soluções, o AG foi executado com o tamanho da população variando entre 100 e 750 indivíduos. Populações com mais de 750 indivíduos se mostraram bastante custosas computacionalmente, o que inviabilizou a sua utilização.

Apesar da população inicial, ou seja, do limite inferior das 20 faixas operativas de todas as UHEs da configuração, ser gerada de maneira aleatória, optou-se neste trabalho pela inclusão exógena de 4 indivíduos à população inicial. As configurações de tais indivíduos são baseadas na experiência do usuário do modelo SUIISHI. Com isso, a população inicial adotada foi a seguinte:

Indivíduo 1 - Configuração *default* do modelo SUIISHI para todas as usinas;

Indivíduo 2 - Para grandes reservatórios de montante em determinadas cascatas, adotou-se amplitudes maiores para as 4 primeiras faixas operativas (variando-as de 9% a 6% do volume útil), e amplitudes menores para as 4

últimas faixas operativas (variando-as de 4% a 1%) destas usinas. Nas situações em que os reservatórios se encontram cheios, tal configuração tem por objetivo dar uma prioridade ainda maior ao deplecionamento dos reservatórios de montante, uma vez que tais usinas possuem as maiores produtibilidades acumuladas, ou seja, a vazão defluente nestas usinas poderá ser turbinada por todas as usinas a jusante. Por outro lado, nas situações em que os reservatórios se encontram vazios, tal configuração irá reduzir ainda mais a prioridade de enchimento destes mesmos reservatórios, uma vez que o acúmulo de água em usinas de montante não traz nenhum ganho de produtividade para as demais usinas da cascata. Neste caso, os reservatórios de montante que tiveram as suas faixas operativas alteradas foram: Batalha, Serra do Facão, Três Marias, Serra da Mesa, Jaguari, Paraibuna, Furnas, Nova Ponte, Barra Bonita, A.A. Laydner, Mauá, G.B. Munhoz e Barra Grande. Para as demais usinas adotou-se a configuração *default* do modelo SUISEI;

Indivíduo 3 - Para grandes reservatórios de jusante em determinadas cascatas, adotou-se amplitudes menores para as 4 primeiras faixas operativas superiores (variando-as de 1% a 4% do volume útil), e amplitudes maiores para as 4 últimas faixas operativas inferiores (variando-as de 6% a 9%) destas usinas. Nas situações em que os reservatórios se encontram vazios, tal configuração tem por objetivo dar uma prioridade ainda maior ao enchimento dos reservatórios de jusante, uma vez que o acúmulo de água nestas usinas eleva a produtividade acumulada de todas as usinas da cascata. Por outro lado, nas situações em que os reservatórios se encontram cheios, tal configuração irá reduzir ainda mais a prioridade de deplecionamento destes reservatórios, uma vez que os mesmos possuem menor produtividade acumulada quando comparada as demais UHEs da cascata. Neste caso, os reservatórios de jusante que tiveram as suas faixas operativas alteradas foram: Funil, Capivara, Machadinho, Itaparica e Tucuruí. Para as demais usinas adotou-se a configuração *default* do modelo SUISEI;

Indivíduo 4 - Considera conjuntamente as características dos indivíduos 2 e 3;

Indivíduos 5 em diante – Gerados aleatoriamente.

A Figura 6 traz uma representação esquemática do cromossomo associado ao Indivíduo 4.

Neste ponto é importante ressaltar que a operação realizada pelo modelo SUSHI continuará tentando equilibrar os volumes dos reservatórios em uma mesma faixa operativa, tal como descrito na seção 3, entretanto, por meio da mudança na amplitude das faixas operativas definida pelo AG, espera-se que o modelo passe a acentuar ainda mais o deplecionamento e/ou o enchimento nas usinas de maior conveniência para a operação.

64748 PROZANTE	64748 JUZANTE		64748 SUS48
91%	99%	K	95%
83%	97%	Λ	90%
76%	94%	Λ	85%
70%	90%	Λ	80%
65%	85%	Λ	75%
60%	80%	Λ	70%
M	M	M	M
15%	35%	Λ	25%
10%	30%	Λ	20%
6%	24%	Λ	15%
3%	17%	Λ	10%
1%	9%	Λ	5%
0%	0%	Λ	0%

Figura 6 – Representação do cromossomo do indivíduo 4

Finalmente, outra característica importante da população é a substituição da geração atual por uma nova geração. Normalmente, substituem-se todos os indivíduos da geração atual pela nova geração, porém, dessa forma, não há garantias de que a população seguinte apresentará uma

solução tão boa quanto, ou melhor do que a melhor solução atual, podendo apresentar apenas soluções piores e ocasionando a perda de boas soluções.

Para garantir que o AG nunca perca suas melhores soluções, pode-se adotar a técnica do elitismo, que consiste em manter as melhores soluções da geração atual durante a substituição da população. Tal procedimento garante que a geração seguinte sempre terá, no mínimo, uma solução tão boa quanto à geração anterior. Neste estudo as 4 melhores soluções de uma população são sempre levadas para a população seguinte.

4.4. Método de Seleção de Pais

O método de seleção de pais para a formação de novos indivíduos deve simular o mecanismo de seleção natural, ou seja, quanto melhor avaliado for um indivíduo dentro de uma população, maior as chances dele ser escolhido para ser pai. Os dois métodos mais difundidos são:

- **Roleta Viciada:** A probabilidade de um indivíduo ser escolhido é igual a sua avaliação, dividida pela soma das avaliações de todos os indivíduos dentro de uma população. Conforme o algoritmo progride e a convergência genética se aproxima, a pressão seletiva diminui devido à similaridade entre os indivíduos.
- **Torneio:** Seleciona-se aleatoriamente uma quantidade de indivíduos e, dentre esses, o indivíduo de maior avaliação é escolhido como pai. Caso o torneio seja muito pequeno, a pressão seletiva é baixa e o algoritmo se aproxima de uma busca aleatória. Caso o torneio seja muito grande, um indivíduo prevalecerá sempre forçando uma convergência genética prematura.

Neste trabalho, optou-se pela utilização do método da Roleta Viciada, onde a probabilidade de cada indivíduo ser selecionado como um dos pais é a seguinte:

$$p(c) = \frac{\left(\frac{1}{FA_c}\right)}{\sum_{i=1}^{NC} \left(\frac{1}{FA_i}\right)} \quad (2)$$

onde $p(c)$ representa a probabilidade do indivíduo c (ou cromossomo) ser escolhido como um pai, e NC representa o número de indivíduos dentro da população. Como o problema estudado consiste na minimização de uma função objetivo, as maiores probabilidades de seleção foram associadas aos indivíduos com menor valor para a sua Função Aptidão.

4.5. Operadores Genéticos

Uma vez selecionados 2 pais, as suas características (ou genes) devem ser combinados para a geração de dois novos indivíduos de uma nova população. Esta combinação é realizada pelos chamados operadores genéticos. Os operadores genéticos são divididos em dois tipos:

- *Crossover*: baseado no cruzamento entre cromossomos, determina-se um ponto de corte nos dois pais selecionados e trocam-se as partes entre os pais de forma a se obter novos indivíduos. Existem vários tipos de operadores *crossover*, dentre os quais destacam-se os operadores de um e de dois pontos de corte, além do *crossover* uniforme;
- *Mutação*: o operador de mutação altera o valor de um gene para um alelo aleatório dentro do alfabeto.

O operador de *crossover* utilizado no presente trabalho é o *crossover* uniforme, que funciona da seguinte forma: após a seleção dos pais, faz-se um sorteio, para cada gene do cromossomo, determinando-se de qual pai o primeiro filho receberá o gene, enquanto o segundo filho receberá o gene do pai não escolhido. Após concluída a geração dos dois novos indivíduos, o processo se repete até que a nova população esteja completa. Desta forma, espera-se que os novos indivíduos contenham mudanças que possam melhorar a qualidade da solução encontrada. O funcionamento do operador de

crossover uniforme é ilustrado na Figura 7 para o problema estudado neste trabalho.




Figura 7 – Ilustração do *crossover* uniforme

Neste trabalho, o operador genético de mutação também foi utilizado. Neste caso, alguns genes de um determinado indivíduo da população são aleatoriamente selecionados, e o valor dos seus alelos são alterados, substituindo-os por uma seqüência de números aleatórios contidos no intervalo [0 ; 0,999] ordenada de forma decrescente.

Em cada nova população, a probabilidade **p** de um indivíduo sofrer mutação é estabelecida pela seguinte equação:

$$p(i+1) = \left(1 - \frac{\Delta FA_i}{\max_{1 \leq j \leq i} \Delta FA_j} \right) \times 0,10 \tag{3}$$

onde *i* representa a iteração atual do AG, *j* representa uma iteração qualquer do AG, ΔFA é a diferença entre a aptidão média e a melhor aptidão da população, e o operador $\max \Delta FA$ representa o maior valor de ΔFA observado entre todas as iterações do AG.

Desta forma, o operador de mutação implementado é adaptativo, ou seja, quanto menor for a diferença entre a melhor aptidão e a aptidão média de uma dada população, maior será a probabilidade dos indivíduos da população seguinte (*i*+1) sofrerem mutação. Note que, de acordo com equação 3, a

probabilidade máxima de cada indivíduo de uma dada população sofrer mutação é limitada a 10%.

4.6. Critério de convergência

Três os critérios de convergência foram adotados neste trabalho, a saber:

- número mínimo de iterações do AG igual a 250 iterações;
- estabilidade da função de aptidão da melhor solução por, no mínimo, 10 gerações;
- diferença entre a melhor aptidão e a aptidão média de última geração inferior a 1%.

5. Abordagem Metodológica do Problema

Uma vez colocados os principais conceitos relacionados aos Algoritmos Genéticos e ao problema objeto de estudo neste trabalho, descreve-se nesta seção a abordagem metodológica empregada para a solução do mesmo. A Figura 8 traz uma representação esquemática do processo de solução adotado.

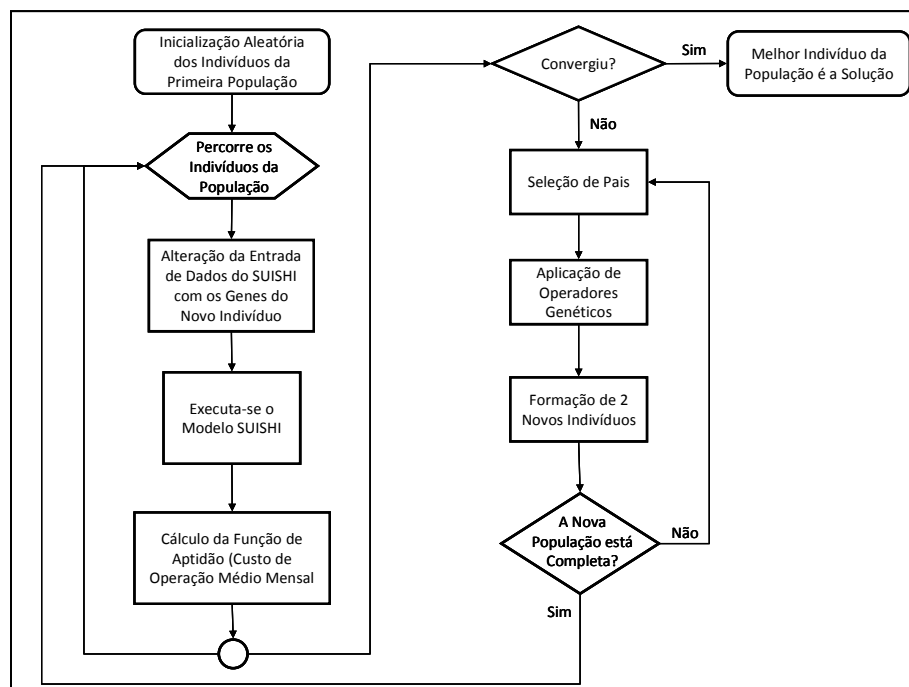


Figura 8 - Fluxograma simplificado do algoritmo de solução do problema

O primeiro passo é a inicialização aleatória dos indivíduos da primeira população de acordo com o tamanho desejado para a mesma. Tal como mostrado na Figura 5, tal população pode ser representada por uma matriz de 20 x NUS, onde o número 20 se refere ao número de faixas operativas usualmente consideradas pelo modelo SUISHI, e NUS representa o número de usinas hidroelétricas com reservatório do caso analisado.

Em seguida, para todos os indivíduos da população, alimenta-se o modelo SUISHI com as faixas operativas do indivíduo avaliado (isto é feito por

meio do arquivo CONFHD). O modelo é então executado, e a função de aptidão do indivíduo é determinada por meio do cálculo do custo de operação médio mensal, tal como descrito na equação 1. A função de aptidão média, considerando todos os indivíduos da população, também é calculada por meio da seguinte equação:

$$AM_i = \frac{\sum_{c=1}^{NC} FA_c}{NC} \quad (4)$$

onde AM_i representa a aptidão média da população avaliada na iteração i do AG.

Uma vez determinada a melhor aptidão e a aptidão média de uma dada população (ou geração), verifica-se o atendimento aos critérios de convergência previamente descritos na seção 4.6. Caso o AG não tenha convergido, uma nova geração de indivíduos será formada. Para tanto, dentre os indivíduos da população atual, dois pais são selecionados e combinados por meio da aplicação do operador denominado *crossover* uniforme, dando origem a dois indivíduos da nova população. Esse processo é repetido até que uma nova população seja completamente formada. Vale ressaltar que cada nova geração de indivíduos sempre conterà os 4 melhores indivíduos da geração anterior.

A nova população é avaliada e os critérios de convergência são novamente testados. Este processo se repete até que, no mínimo, todos os critérios de convergência sejam satisfeitos.

6. Resultados

Para a aplicação do Algoritmo Genético ao problema proposto neste trabalho foi utilizada a plataforma de dados do Plano Mensal de Operação (PMO) do mês de Abril de 2013 para a execução dos modelos NEWAVE e SUIISHI. Uma das premissas deste PMO é a divisão do Sistema Interligado Nacional (SIN) em 4 subsistemas. Neste trabalho, esta premissa foi alterada considerando-se o SIN como um subsistema único, o que possibilitou uma significativa redução do custo computacional para a execução do AG⁴. Outras premissas deste trabalho são:

- Consideração de um patamar de carga único;
- Utilização da séries históricas de vazões;
- Utilização dos modelos NEWAVE versão 17 e SUIISHI versão 7.8.1.

Nas próximas seções os resultados obtidos serão apresentados em três partes: análises de convergência e melhor solução; resultados para o caso subsistema único; e resultados para o caso com 4 subsistemas.

6.1. Análises de Convergência e Melhor Solução

Tal como dito na seção 4.3, considerando que o problema em questão possui um grande espaço de possíveis soluções, não foi possível estabelecer *a priori* um número adequado para o tamanho da população. Por este motivo, foi realizada uma análise de sensibilidade do desempenho do AG com relação ao tamanho da população utilizada, variando-a entre 100 e 750 indivíduos. Populações com mais de 750 indivíduos se mostraram bastante custosas computacionalmente, o que inviabilizou a sua utilização.

⁴ Utilizando-se um processador AMD A8-3500 1.5GHz, o tempo de execução do modelo SUIISHI para o PMO de Abril de 2013 com 4 subsistemas é de aproximadamente 835 segundos, enquanto que, considerando o subsistema único, este tempo é reduzido para 88 segundos. Por exemplo, supondo uma população de 100 indivíduos, vale ressaltar que cada iteração do Algoritmo Genético irá implicar na avaliação dos 100 indivíduos da população, o que significa a execução de 100 casos SUIISHI.

As Figuras 9 a 12 ilustram a convergência do AG considerando o tamanho da população respectivamente igual a 100, 250, 500 e 750 indivíduos. Em todos os casos, além do valor da aptidão média e da melhor aptidão em cada iteração, também está ilustrado como estes resultados se comparam ao valor da função de aptidão calculada com base na configuração *default* adotada no modelo SUIHI (indivíduo 1 descrito na seção 4.3), e com base na configuração adotada para o Indivíduo 4. Os Indivíduos 2 e 3 apresentaram um desempenho inferior ao do Indivíduo 4 e por isso não se encontram ilustrados nas figuras a seguir.

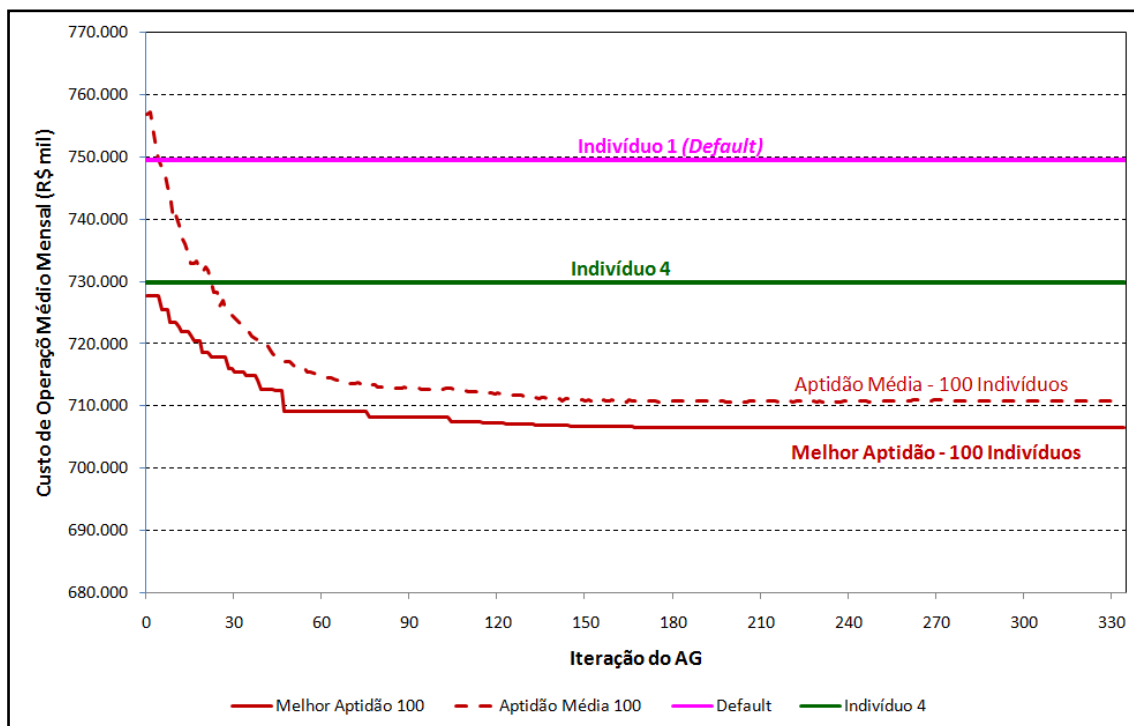


Figura 9 - Convergência do AG para uma População de 100 Indivíduos




Figura 10 - Convergência do AG para uma População de 100/250 Indivíduos

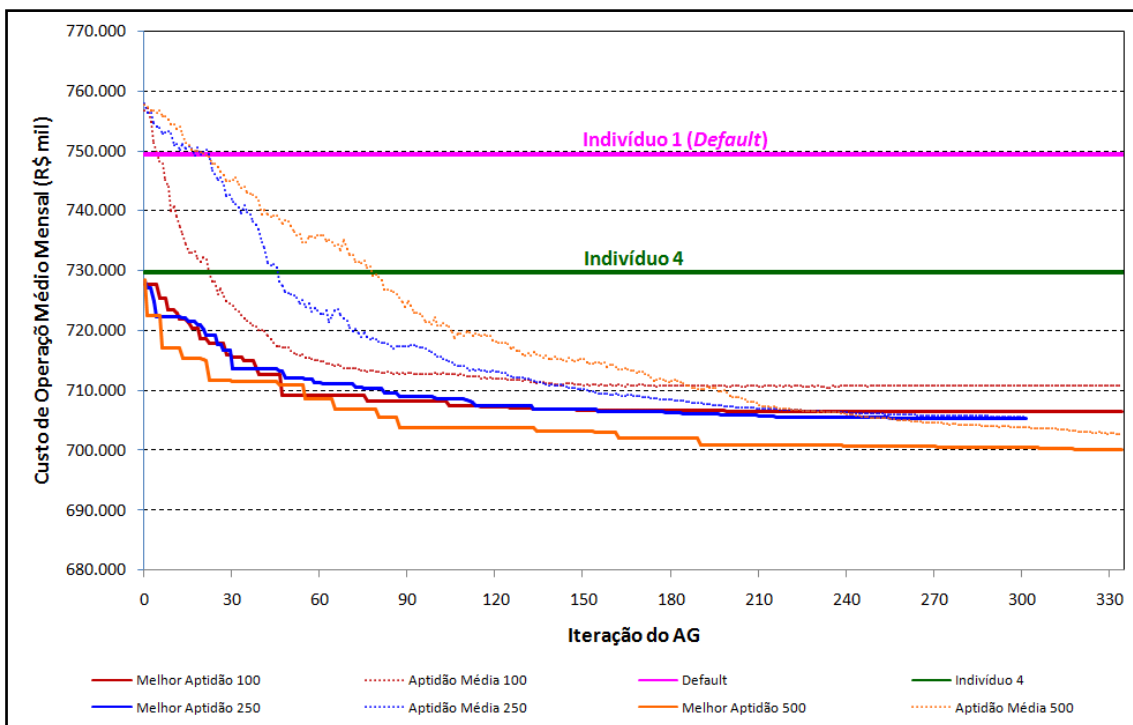


Figura 11- Convergência do AG para uma População de 100/250/500 Indivíduos

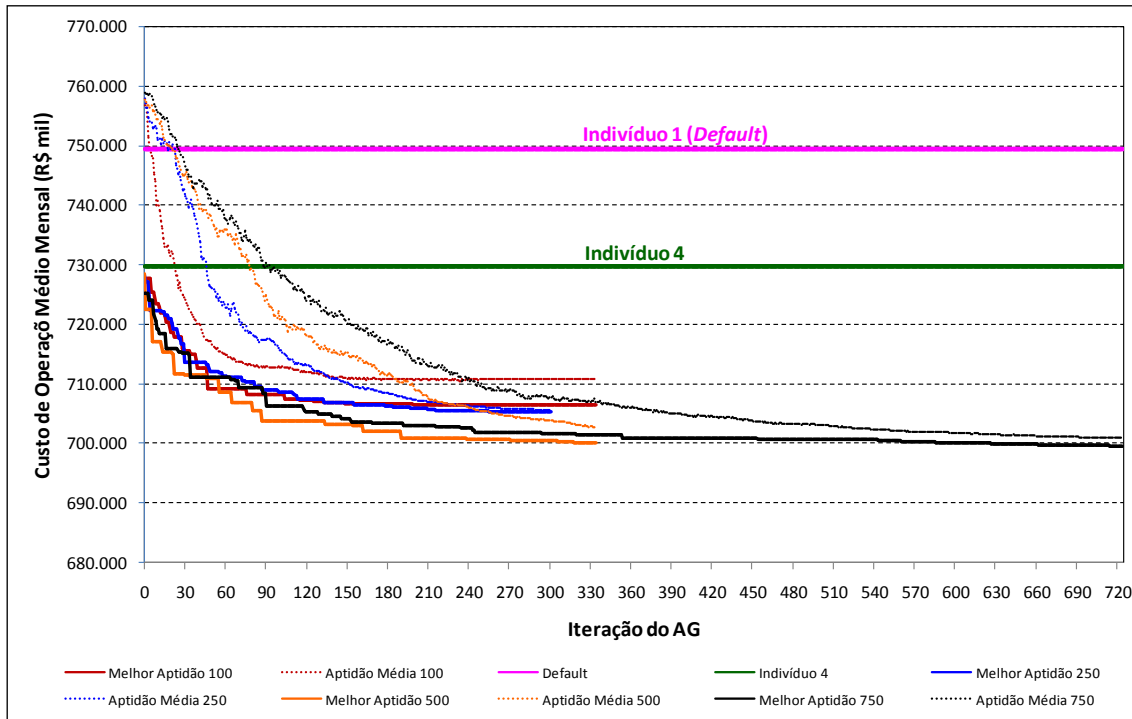


Figura 12 - Convergência do AG para uma População de 100/250/500/750 Indivíduos

Os resultados ilustrados nas figuras anteriores mostram que a configuração de faixas operativas do Indivíduo 4 leva a uma redução de aproximadamente 2,7% no custo de operação médio quando comparado à configuração *default* atualmente utilizada pelo SUIHI. Isso mostra que a inclusão deste indivíduo na população inicial pode contribuir tanto para a qualidade da solução final quanto para a velocidade de convergência do algoritmo.

Adicionalmente nota-se que na primeira iteração do AG, independente do tamanho da população adotada, as função de aptidão das melhores soluções (ou melhores aptidões) possuem valores muito próximos entre si, e muito próximos do valor da aptidão do indivíduo 4. Isto ocorre porque em todos

os casos a geração aleatória de indivíduos da população não levou a uma solução melhor do que aquela associada ao Indivíduo 4, tendo este indivíduo uma forte influência genética nas melhores aptidões obtidas após a primeira iteração do AG. Este fato pode indicar que mesmo populações de 750 indivíduos não são suficientes para representar adequadamente o espaço de soluções do problema, ou ainda que a geração aleatória de indivíduos para a população inicial não é a melhor estratégia para o problema proposto.

Analisando-se os valores das aptidões médias, também é possível observar que, inicialmente, as mesmas possuem valores muito próximos entre si, independente do tamanho da população. Note ainda que quanto maior o número de indivíduos, maior é a diferença entre a melhor aptidão e a aptidão média nas primeiras iterações, o que provavelmente se deve a um aumento da dispersão dos valores das funções aptidões com o aumento do número de indivíduos na população. Neste caso, quanto maior a população, também se espera um maior número de iterações (e, conseqüentemente, tempo computacional) para a convergência do algoritmo, tal como observado na Figura 12.

Finalmente, nota-se na Figura 12 que a melhor solução foi obtida após 720 iterações para uma população de 750 indivíduos, com custo médio de operação igual a R\$ 699,6 milhões. Também é possível observar que esta solução se mostrou muito próxima à melhor solução obtida com a população de 500 indivíduos. Apesar de bastante sugestivo, ainda consideramos prematura a conclusão de que populações superiores a 750 indivíduos representariam pouca melhoria na qualidade dos resultados frente ao ganho de custo computacional.

O conjunto completo das faixas operativas obtido para a solução de melhor aptidão é apresentado a seguir. A Tabela 1 apresenta os limites inferiores das 20 faixas utilizadas para cada reservatório do sistema, enquanto que a Tabela 2 apresenta a amplitude das faixas, ambos em valores percentuais do volume útil dos reservatórios.

Tabela 1 - Limites Inferiores das Faixas Operativas para a Solução de Melhor
Aptidão (% do Volume Útil)

Centro de Pesquisas de Energia Elétrica - CEPEL



Relatório Técnico – 27628/2017

1	BATALHA	99,4	95,3	83,2	81,3	77,2	74,7	73,6	71,6	66,5	62,2	44,4	44,3	35,6	34,3	23,5	22,7	15,1	14,5	6,7	0
2	SERRA FACAÓ	96,3	88,5	83,7	72,7	70,4	58,6	56,2	54,8	46,8	33,6	33	32,6	26,5	24,5	22	21,3	19,1	8,4	8	0
3	CAPIM BRANCI	93,8	90,6	84,2	81,9	77,4	76,8	62,4	57,5	44,9	44,5	41,8	41,2	31,7	31,1	30,9	21,8	17,7	8,6	5,5	0
4	CORUMBA IV	91,8	89,6	81,3	78,9	75,2	68,6	64,1	58,2	57,2	56,6	43,3	41,4	40,1	31,4	18,5	12,2	11,9	9,4	4,5	0
5	RETIRO BAIXO	94,2	91,3	83,5	78,2	76,7	76,5	75,9	63,8	61,7	58,5	54,6	43,7	41,2	41	39,7	35,2	30,6	26	19,1	0
6	TRES MARIAS	91,9	91,3	91	90,4	90,3	89,4	88	78,3	65,1	63	42,1	36	30,5	25,2	23,2	18,6	14,9	14,8	9,5	0
7	QUEIMADO	88,4	88,2	79,7	76,2	71,6	64,1	63,8	58,1	57,9	37,9	35,5	33	26,9	26,2	19,4	8,5	8	4,8	0,7	0
8	CORUMBA III	98,2	93,5	89,8	89,3	76	68,2	58,1	49,1	46,4	45,9	39,5	36,2	27,4	27,3	25,6	19,9	19,1	9,5	8,2	0
9	SERRA MESA	95,9	85,5	75,8	62,6	59,6	42	40,6	38,9	25,8	22,4	21,8	20,7	17,5	14,3	11,4	11,4	10,4	7,2	6,3	0
10	PEIXE ANGIC	98,7	95,7	95,6	92,5	90	85,6	78,4	66,5	64,5	59,2	46,9	43,6	36,1	34,9	34,1	29,4	27,4	19	16	0
11	RONDON II	88,1	84,9	84,6	79	78,9	78,4	72,1	69,1	67,1	64,7	60,3	57,8	50,6	50,1	43,4	34,7	28,2	21	13,8	0
12	ESPORA	99,7	98	95,5	93,1	86,3	82,7	74,6	68,7	56,5	54,5	48,4	42,3	38,7	38,5	28	19,9	16,3	15,7	9,1	0
13	CACU	92	84,8	72,4	63,1	62,8	59,4	53,5	52,6	51	50,1	48,9	47,2	45,6	42,3	41,3	32,9	16,8	9,4	4,3	0
14	FICT.MAUA	95,9	85,5	68,4	67,2	64,6	63,5	62,7	62,5	61,1	59,7	58,8	54,1	53,7	46,6	43,5	35	24	16,7	9,9	0
15	JAGUARI	79,2	70,5	68,9	61,5	60	56,3	55,8	55,5	53,1	46,3	33,8	30,3	26,8	26,2	20,7	13	11,8	10,6	3,7	0
16	PARAIBUNA	99,9	99,6	92	87,6	85,8	73,4	69,1	66,8	47,9	44	40,8	40,6	31,8	29	25,9	25,3	16,6	15,8	9,2	0
17	SANTA BRANCA	98,7	97,1	94,2	87,3	60,8	57,9	51	46,3	43,7	40,8	37,2	36,2	33,9	29,9	21,5	18,5	11,4	9,4	0,1	0
18	FUNIL	95,7	91,2	82,7	79,5	75,1	69,3	67,2	61,1	57,9	49,6	45,8	44,5	44,3	44	36,8	33,4	32,5	15,4	13	0
19	LAJES	98,6	98	97,4	94,6	93,5	92,5	91,4	78,7	73,7	62,2	60,1	57,3	50,7	42,7	32,7	27	26,8	12,2	8	0
20	P. ESTRELA	91	89,7	89,3	88,9	80	78,8	77,4	75,3	74,4	74,2	64,9	62,1	61,1	50,1	49,5	43	35,9	15,4	7,2	0
21	SAMUEL	97,9	97,8	90,2	85,4	84,8	81,9	77,9	75,9	74,1	73,1	72,6	66,2	53,1	52,7	41,3	39,3	35,3	31,8	16,1	0
22	IRAPE	94,6	87,2	85,1	85	83,8	81	77,8	75,5	71,8	63,4	58,7	57,9	44,7	35,5	34,1	28,8	22,5	19,5	6,8	0
23	CAMARGOS	99,9	98,6	92,5	92,2	91,9	87,4	84,5	77,4	65,6	63	59,8	55,6	39,4	38,8	37,4	36,4	31,2	27,9	21,5	0
24	FURNAS	99,8	98,5	98	97,3	83,4	78,3	73,2	61,6	51,3	50,7	40,4	39,8	39	34,1	28	21,9	12,8	5,3	5,2	0
25	M. DE MORAES	97,8	97,1	88,9	85,2	85	79,5	76,8	75,5	63,3	55,2	47,6	42,8	39,3	33,1	23	21,4	20,4	19,8	10,6	0
26	CACONDE	99,8	96,6	96,3	94,9	91,1	89,3	76	75,3	67,4	63,6	55,9	48	48	46,6	44	30,5	19,4	6,7	4,3	0
27	MARIMBONDO	94,3	90	89,7	89,2	88,6	82,7	81	80,9	75,6	75,6	69,5	68,8	65,6	61,2	49,4	47,4	43,7	38,9	27,5	0
28	A. VERMELHA	99,2	95,1	93,5	84,8	81,8	74,4	73	71,9	69,6	66,1	65,3	57,5	54,8	49,5	45	41,4	36,6	32,8	32,8	0
29	EMBORCACAO	96,2	93,7	86,2	72,6	69,3	64,9	56,2	54,7	46,4	44,7	41,2	38,2	30,1	27,3	21,4	16,5	14	3,3	1	0
30	NOVA PONTE	95,5	78,7	71,6	64,8	62,3	59	52,6	43,2	41,8	29,8	27,5	25,6	25,4	25,1	13	12,8	11	6,3	3,7	0
31	MIRANDA	99,8	98,2	95,1	94,3	89,7	89,3	85,1	80,4	79,5	78,6	76,6	72,7	56,7	55,5	53,1	51,2	48,1	45,6	27,2	0
32	CORUMBA I	96,6	94,5	91,5	89,1	86,1	79,6	78,4	69,6	62,2	60	57,4	49,6	46,8	44	43,3	42,1	40,1	12,7	4,7	0
33	ITUMBIARA	93,3	92,7	91,9	91,6	87,4	85,7	85,3	82,1	73,7	65,4	61,1	59,9	55,4	54,5	53,8	53,2	48,4	45,4	25,9	0
34	SAO SIMAO	97,6	89,6	85,9	85,3	80,9	80,6	76,3	66,9	65,8	61,9	59,4	58,9	57,2	53,1	51,7	45,7	43,7	31,3	21,5	0
35	BARRA BONITA	95,5	95	93,8	81	80,3	79,9	78,7	71,7	69	67,6	66,4	58,2	53,8	50,8	49,7	25,8	19	13,5	0	
36	PROMISSAO	97,5	87,4	77,2	75,3	70,2	68,9	57	54,7	53,9	53,7	41,3	35,8	35,6	35,5	33,5	30,3	25,4	25	6,1	0
37	GUARAPIRANGA	92,8	84,8	74,4	66,3	63,5	60,8	55,8	54,6	53,9	45,2	44,5	38,1	37,1	36,8	34,3	20,7	18	17,9	12,9	0
38	BILLINGS	99,4	97,3	94,3	91,5	90,2	90,1	88,5	88,2	77,5	75,3	73,9	73,1	57,2	52,1	51,7	46,6	38,5	13,2	9,9	0
39	I. SOLT. EQV	99,9	92,7	92	86,5	81,7	80,7	77,7	75,3	74,2	72,9	71,3	64,3	58,7	31,2	27,7	24,1	20,4	11,9	7,5	0
40	MANSO	97,6	96,2	91,6	89,7	86,8	80	79	74,6	63,7	61,9	59	47,1	46,9	39	32,2	24,6	23,1	23	13,5	0
41	A.A. LAYDNER	95,6	89,6	66,2	66,1	65,5	63,4	53,5	45	44	38,8	27,1	24,9	24,2	22,5	21,9	15,7	15,1	13,2	12,2	0
42	CHAVANTES	97,9	91,2	79,6	69,8	69,6	60	59,4	54,2	51,6	51,6	50,4	50,4	45,2	34,4	28,8	20,9	20,2	12,8	9,5	0
43	CAPIVARA	93,9	92,7	91,2	88,8	87,5	85,8	85,5	83,9	77,3	75,6	72,7	59,4	55,4	45,9	38,9	37,1	37	31,2	17,1	0
44	MAUA	95,9	90,9	85,3	84	78,3	70,5	62,5	53,6	42,3	38,8	34	28,9	26,9	25,8	23,9	17,4	4,3	3,9	2,3	0
45	STA CLARA PR	98,1	93,9	76,2	71,5	69,2	58,6	56,7	49,3	37,7	36,8	28,2	26,4	22,8	15,3	11,8	8	7,7	5,3	3,3	0
46	G.B. MUNHOZ	99,7	97,5	94,7	91,7	90,9	70,2	62,3	58,4	56,2	47	41,2	35,6	33,1	19,3	13,7	13,3	11,2	11	8,1	0
47	BARRA GRANDE	83,4	81,7	77,6	77,2	67,3	62,2	55,4	55,3	49,4	39,9	34,6	34,2	31,3	29,6	27,9	19,5	14,3	12,1	7,2	0
48	SAO ROQUE	96,7	92	91,7	91,1	84,9	58,2	53,1	53	50,4	47,2	38,9	33,4	28,4	26,2	15,2	14,6	10,8	7,1	5,1	0
49	CAMPOS NOVOS	85,5	85,5	82,2	81,4	79,4	70,5	70,3	59,5	53,3	52,7	50,5	46,1	39,1	37,7	29,2	28,4	21,7	15,4	4,3	0
50	MACHADINHO	96,2	92,8	89,6	88,7	86,8	73,6	72,8	71,8	71,2	66,3	56,5	52,3	51,3	42,1	34,8	29,3	25,4	8,3	7,9	0
51	PASSO FUNDO	93,2	89,3	84,1	79,9	75	73,9	56,5	56,1	53,6	49,3	29,7	24,2	23,7	21,7	20,3	19,5	16,6	11,8	10,3	0
52	QUEBRA QUEIX	93,7	92,3	88,2	84,4	79,6	67,1	57,5	46,9	32,9	32,6	28	27,4	21,7	19,6	19	6,9	5,3	4,9	3,2	0
53	ERNESTINA	90,6	89,9	78,8	78,1	70,2	62,7	62,3	51,1	48,3	28,9	24,1	23	18,9	14,3	11	10,1	6	2,5	1,4	0
54	PASSO REAL	99,8	96,7	80,4	66,5	55,2	54,6	52,6	45,5	39,7	34,2	27,2	21,5	21,4	17,5	15,6	15,6	11	9,8	8,5	0
55	G.P. SOUZA	92,6	91,5	83,6	80	78,3	71,5	51,8	49,4	41,9	39,8	35,2	30,4	21,6	21,1	16,9	6	5,6	5	4,9	0
56	JORDAO	90,1	82,5	80,7	75,3	50,4	45	41,9	39,2	38,5	33,3	26,8	26,2	23,5	22,1	16,9	14,2	11,8	10,3	10,2	0
57	SEGREDO	95,9	85,5	68,4	67,2	64,6	63,5	62,7	62,5	61,1	59,7	58,8	54,1	53,7	46,6	43,5	35	24	16,7	9,9	0
58	SLT.SANTIAGO	89,7	85,6	78,9	75,7	67,2	58,2	53,6	47	46,7	46,2	45,9	43,8	41,2	38,2	33	29,6	23,9	15,6	14,1	0
59	SOBRADINHO	93,8	91,1	64,8	55,2	54,8	48,3	45,1	38,7	27,1	24,6	23,8	17,7	15	13,4	8	6	6	4,9	1,8	0
60	ITAPARICA	97,5	97,4	83,9	79,9	79,3	76,1	73,2	71,8	69,3	67,5	55,6	53	48,6	43,4	41,7	36,2	27,7	24,9	7,6	0
61	FICT.QUEIMAD	90,2	89,4	88,7	88	80,5	79,2	72,9	70,4	62,9	60,2	51,2	43,7	40,1	38,4	37,7	23,2	11	9,5	4,3	0
62	FICT.TRES MA	91,9	91,3	91	90,4	90,3	89,4	88	78,3	65,1	63	42,1	36	30,5	25,2	23,2	18,6	14,9	14,8	9,5	0
63	FICT.RETIRO	94,2	91,3	83,5	78,2	76,7	76,5	75,9	63,8	61,7	58,5	54,6	43,7	41,2	41	39,7	35,2	30,6	26	19,1	0
64	FICT.IRAPE	94,6	87,2																		

Tabela 2 - Amplitudes das Faixas Operativas para a Solução de Melhor Aptidão
(% do Volume Útil)

1	BATALHA	0,6	4,1	12,1	1,9	4,1	2,5	1,1	2	5,1	4,3	17,8	0,1	8,7	1,3	10,8	0,8	7,6	0,6	7,8	6,7
2	SERRA FAÇAO	3,7	7,8	4,8	11	2,3	11,8	2,4	1,4	8	13,2	0,6	0,4	6,1	2	2,5	0,7	2,2	10,7	0,4	8
3	CAPIM BRANCI	6,2	3,2	6,4	2,3	4,5	0,6	14,4	4,9	12,6	0,4	2,7	0,6	9,5	0,6	0,2	9,1	4,1	9,1	3,1	5,5
4	CORUMBA IV	8,2	2,2	8,3	2,4	3,7	6,6	4,5	5,9	1	0,6	13,3	1,9	1,3	8,7	12,9	6,3	0,3	2,5	4,9	4,5
5	RETIRO BAIXO	5,8	2,9	7,8	5,3	1,5	0,2	0,6	12,1	2,1	3,2	3,9	10,9	2,5	0,2	1,3	4,5	4,6	4,6	6,9	19,1
6	TRES MARIAS	8,1	0,6	0,3	0,6	0,1	0,9	1,4	9,7	13,2	2,1	20,9	6,1	5,5	5,3	2	4,6	3,7	0,1	5,3	9,5
7	QUEIMADO	11,6	0,2	8,5	3,5	4,6	7,5	0,3	5,7	0,2	20	2,4	2,5	6,1	0,7	6,8	10,9	0,5	3,2	4,1	0,7
8	CORUMBA III	1,8	4,7	3,7	0,5	13,3	7,8	10,1	9	2,7	0,5	6,4	3,3	8,8	0,1	1,7	5,7	0,8	9,6	1,3	8,2
9	SERRA MESA	4,1	10,4	9,7	13,2	3	17,6	1,4	1,7	13,1	3,4	0,6	1,1	3,2	3,2	2,9	0	1	3,2	0,9	6,3
10	PEIXE ANGIC	1,3	3	0,1	3,1	2,5	4,4	7,2	11,9	2	5,3	12,3	3,3	7,5	1,2	0,8	4,7	2	8,4	3	16
11	RONDON II	11,9	3,2	0,3	5,6	0,1	0,5	6,3	3	2	2,4	4,4	2,5	7,2	0,5	6,7	8,7	6,5	7,2	7,2	13,8
12	ESPORA	0,3	1,7	2,5	2,4	6,8	3,6	8,1	5,9	12,2	2	6,1	6,1	3,6	0,2	10,5	8,1	3,6	0,6	6,6	9,1
13	CACU	8	7,2	12,4	9,3	0,3	3,4	5,9	0,9	1,6	0,9	1,2	1,7	1,6	3,3	1	8,4	16,1	7,4	5,1	4,3
14	FICT.MAUA	4,1	10,4	17,1	1,2	2,6	1,1	0,8	0,2	1,4	1,4	0,9	4,7	0,4	7,1	3,1	8,5	11	7,3	6,8	9,9
15	JAGUARI	20,8	8,7	1,6	7,4	1,5	3,7	0,5	0,3	2,4	6,8	12,5	3,5	3,5	0,6	5,5	7,7	1,2	1,2	6,9	3,7
16	PARAIBUNA	0,1	0,3	7,6	4,4	1,8	12,4	4,3	2,3	18,9	3,9	3,2	0,2	8,8	2,8	3,1	0,6	8,7	0,8	6,6	9,2
17	SANTA BRANCA	1,3	1,6	2,9	6,9	26,5	2,9	6,9	4,7	2,6	2,9	3,6	1	2,3	4	8,4	3	7,1	2	9,3	0,1
18	FUNIL	4,3	4,5	8,5	3,2	4,4	5,8	2,1	6,1	3,2	8,3	3,8	1,3	0,2	0,3	7,2	3,4	0,9	17,1	2,4	13
19	LAJES	1,4	0,6	0,6	2,8	1,1	1	1,1	12,7	5	11,5	2,1	2,8	6,6	8	10	5,7	0,2	14,6	4,2	8
20	P. ESTRELA	9	1,3	0,4	0,4	8,9	1,2	1,4	2,1	0,9	0,2	9,3	2,8	1	11	0,6	6,5	7,1	20,5	8,2	7,2
21	SAMUEL	2,1	0,1	7,6	4,8	0,6	2,9	4	2	1,8	1	0,5	6,4	13,1	0,4	11,4	2	4	3,5	15,7	16,1
22	IRAPE	5,4	7,4	2,1	0,1	1,2	2,8	3,2	2,3	3,7	8,4	4,7	0,8	13,2	9,2	1,4	5,3	6,3	3	12,7	6,8
23	CAMARGOS	0,1	1,3	6,1	0,3	0,3	4,5	2,9	7,1	11,8	2,6	3,2	4,2	16,2	0,6	1,4	1	5,2	3,3	6,4	21,5
24	FURNAS	0,2	1,3	0,5	0,7	13,9	5,1	5,1	11,6	10,3	0,6	10,3	0,6	0,8	4,9	6,1	6,1	9,1	7,5	0,1	5,2
25	M. DE MORAES	2,2	0,7	8,2	3,7	0,2	5,5	2,7	1,3	12,2	8,1	7,6	4,8	3,5	6,2	10,1	1,6	1	0,6	9,2	10,6
26	CACONDE	0,2	3,2	0,3	1,4	3,8	1,8	13,3	0,7	7,9	3,8	7,7	7,9	0	1,4	2,6	13,5	11,1	12,7	2,4	4,3
27	MARIMBONDO	5,7	4,3	0,3	0,5	0,6	5,9	1,7	0,1	5,3	0	6,1	0,7	3,2	4,4	11,8	2	3,7	4,8	11,4	27,5
28	A. VERMELHA	0,8	4,1	1,6	8,7	3	7,4	1,4	1,1	2,3	3,5	0,8	7,8	2,7	5,3	4,5	3,6	4,8	3,8	0	32,8
29	EMBORCACAO	3,8	2,5	7,5	13,6	3,3	4,4	8,7	1,5	8,3	1,7	3,5	3	8,1	2,8	5,9	4,9	2,5	10,7	2,3	1
30	NOVA PONTE	4,5	16,8	7,1	6,8	2,5	3,3	6,4	9,4	1,4	12	2,3	1,9	0,2	0,3	12,1	0,2	1,8	4,7	2,6	3,7
31	MIRANDA	0,2	1,6	3,1	0,8	4,6	0,4	4,2	4,7	0,9	0,9	2	3,9	16	1,2	2,4	1,9	3,1	2,5	18,4	27,2
32	CORUMBA I	3,4	2,1	3	2,4	3	6,5	1,2	8,8	7,4	2,2	2,6	7,8	2,8	2,8	0,7	1,2	2	27,4	8	4,7
33	ITUMBIARA	6,7	0,6	0,8	0,3	4,2	1,7	0,4	3,2	8,4	8,3	4,3	1,2	4,5	0,9	0,7	0,6	4,8	3	19,5	25,9
34	SAO SIMAO	2,4	8	3,7	0,6	4,4	0,3	4,3	9,4	1,1	3,9	2,5	0,5	1,7	4,1	1,4	6	2	12,4	9,8	21,5
35	BARRA BONITA	4,5	0,5	1,2	12,8	0,7	0,4	1,2	7	2,7	1,4	1,2	8,2	2	2,4	3	1,1	23,9	6,8	5,5	13,5
36	PROMISSAO	2,5	10,1	10,2	1,9	5,1	1,3	11,9	2,3	0,8	0,2	12,4	5,5	0,2	0,1	2	2,2	5,9	0,4	18,9	6,1
37	GUARAPIRANGA	7,2	8	10,4	8,1	2,8	2,7	5	1,2	0,7	8,7	0,7	6,4	1	0,3	2,5	13,6	2,7	0,1	5	12,9
38	BILLINGS	0,6	2,1	3	2,8	1,3	0,1	1,6	0,3	10,7	2,2	1,4	0,8	15,9	5,1	0,4	5,1	8,1	25,3	3,3	9,9
39	I. SOLT. EQV	0,1	7,2	0,7	5,5	4,8	1	3	2,4	1,1	1,3	1,6	7	5,6	27,5	3,5	3,6	3,7	8,5	4,4	7,5
40	MANSO	2,4	1,4	4,6	1,9	2,9	6,8	1	4,4	10,9	1,8	2,9	11,9	0,2	7,9	6,8	7,6	1,5	0,1	9,5	13,5
41	A.A. LAYDNER	4,4	6	23,4	0,1	0,6	2,1	9,9	8,5	1	5,2	11,7	2,2	0,7	1,7	0,6	6,2	0,6	1,9	1	12,2
42	CHAVANTES	2,1	6,7	11,6	9,8	0,2	9,6	0,6	5,2	2,6	0	1,2	0	5,2	10,8	5,6	7,9	0,7	7,4	3,3	9,5
43	CAPIVARA	6,1	1,2	1,5	2,4	1,3	1,7	0,3	1,6	6,6	1,7	2,9	13,3	4	9,5	7	1,8	0,1	5,8	14,1	17,1
44	MAUA	4,1	5	5,6	1,3	5,7	7,8	8	8,9	11,3	3,5	4,8	5,1	2	1,1	1,9	6,5	13,1	0,4	1,6	2,3
45	STA CLARA PR	1,9	4,2	17,7	4,7	2,3	10,6	1,9	7,4	11,6	0,9	8,6	1,8	3,6	7,5	3,5	3,8	0,3	2,4	2	3,3
46	G.B. MUNHOZ	0,3	2,2	2,8	3	0,8	20,7	7,9	3,9	2,2	9,2	5,8	5,6	2,5	13,8	5,6	0,4	2,1	0,2	2,9	8,1
47	BARRA GRANDE	16,6	1,7	4,1	0,4	9,9	5,1	6,8	0,1	5,9	9,5	5,3	0,4	2,9	1,7	1,7	8,4	5,2	2,2	4,9	7,2
48	SAO ROQUE	3,3	4,7	0,3	0,6	6,2	26,7	5,1	0,1	2,6	3,2	8,3	5,5	5	2,2	11	0,6	3,8	3,7	2	5,1
49	CAMPOS NOVOS	14,5	0	3,3	0,8	2	8,9	0,2	10,8	6,2	0,6	2,2	4,4	7	1,4	8,5	0,8	6,7	6,3	11,1	4,3
50	MACHADINHO	3,8	3,4	3,2	0,9	1,9	13,2	0,8	1	0,6	4,9	9,8	4,2	1	9,2	7,3	5,5	3,9	17,1	0,4	7,9
51	PASSO FUNDO	6,8	3,9	5,2	4,2	4,9	1,1	17,4	0,4	2,5	4,3	19,6	5,5	0,5	2	1,4	0,8	2,9	4,8	1,5	10,3
52	QUEBRA QUEIX	6,3	1,4	4,1	3,8	4,8	12,5	9,6	10,6	14	0,3	4,6	0,6	5,7	2,1	0,6	12,1	1,6	0,4	1,7	3,2
53	ERNESTINA	9,4	0,7	11,1	0,7	7,9	7,5	0,4	11,2	2,8	19,4	4,8	1,1	4,1	4,6	3,3	0,9	4,1	3,5	1,1	1,4
54	PASSO REAL	0,2	3,1	16,3	13,9	11,2	0,6	2	7,1	5,8	5,5	7	5,7	0,1	3,9	1,9	0	4,6	1,2	1,3	8,5
55	G.P. SOUZA	7,4	1,1	7,9	3,6	1,7	6,8	19,7	2,4	7,5	2,1	4,6	4,8	8,8	0,5	4,2	10,9	0,4	0,6	0,1	4,9
56	JORDAO	9,9	7,6	1,8	5,4	24,9	5,4	3,1	2,7	0,7	5,2	6,5	0,6	2,7	1,4	5,2	2,7	2,4	1,5	0,1	10,2
57	SEGREDO	4,1	10,4	17,1	1,2	2,6	1,1	0,8	0,2	1,4	1,4	0,9	4,7	0,4	7,1	3,1	8,5	11	7,3	6,8	9,9
58	SLT.SANTIAGO	10,3	4,1	6,7	3,2	8,5	9	4,6	6,6	0,3	0,5	0,3	2,1	2,6	3	5,2	3,4	5,7	8,3	1,5	14,1
59	SOBRADINHO	6,2	2,7	26,3	9,6	0,4	6,5	3,2	6,4	11,6	2,5	0,8	6,1	2,7	1,6	5,4	2	0	1,1	3,1	1,8
60	ITAPARICA	2,5	0,1	13,5	4	0,6	3,2	2,9	1,4	2,5	1,8	11,9	2,6	4,4	5,2	1,7	5,5	8,5	2,8	17,3	7,6
61	FICT.QUEIMAD	9,8	0,8	0,7	0,7	7,5	1,3	6,3	2,5	7,5	2,7	9	7,5	3,6	1,7	0,7	14,5	12,2	1,5	5,2	4,3
62	FICT.TRES MA	8,1	0,6	0,3	0,6	0,1	0,9	1,4	9,7	13,2	2,1	20,9	6,1	5,5	5,3	2	4,6	3,7	0,1	5,3	9,5
63	FICT.RETIRO	5,8	2,9	7,8	5,3	1,5	0,2	0,6	12,1	2,1	3,2	3,9	10,9	2,5	0,2	1,3	4,5	4,6	4,6	6,9	19,1
64	FICT.IRAPE	5,4	7,4	2,1	0,1	1,2	2,8	3,2	2,3	3,7	8,4	4,7	0,8	13,2	9,2	1,4	5,3	6,3	3	12,7	6,8
65	P. CAVALO	9,3	3,7	9	2,9	0,5	2	0,9	9,7	12,7	3,1	1,2	8,5	5,9	2	14,4	0,3	2,2	5,2	3	3,5
66	B. ESPERANCA	1,1	1,3	4,1	1,1	0,8	0,6	14,8	0,5	1,4	5,2	2,6	5,4	3,5	0	15,6	3,2	4,9	5,6	2,8	25,5
67	TUCURUI	0,5	3,4	0,4	1,9	6,9	1,9	0,9	1,2	3,4	4,8	8,1	1,9	2,9	3,5	5,4	3	2,5	27,6	9,7	10,1
68	BALBINA	6,3	5,8	2,2	0,8	1	8,3	1,2	8,2	1,5	2,3	6,3	1,6	5,2	0,7	1,6					

6.2. Resultados Subsistema Único

Nesta seção os resultados apresentados na seção anterior serão melhor detalhados. O objetivo é verificar o comportamento médio e temporal de outros parâmetros além do custo de operação, o qual foi utilizado como função de aptidão. Neste caso também foram analisados o custo marginal de operação, a energia armazenada final, o déficit de geração, a geração hidráulica total e a geração térmica total. As figuras a seguir se referem aos resultados médios mensais de todo o histórico de vazões (1931-2011).




Figura 13 - Custo Total de Operação




Figura 14 - Custo Marginal de Operação




Figura 15 - Energia Armazenada Final




Figura 16 - Déficit de Geração




Figura 17 - Geração Hidráulica Total + Excesso de Geração




Figura 18 - Geração Térmica Total

Os resultados ilustrados nas Figuras 13 a 18 mostram, principalmente, que as faixas operativas obtidas para a melhor solução do caso com 750 indivíduos leva, em média, à uma redução no custo de operação do sistema, no custo marginal de operação, no déficit de geração e na geração térmica total quando comparada aos resultados obtidos por meio da configuração *default* atualmente adotada no modelo SUIHI. Ao mesmo tempo, observa-se níveis aproximadamente idênticos na energia armazenada final e na geração hidráulica total do sistema. Os resultados da Tabela 3 corroboram com o descrito anteriormente, sendo observada uma redução média de aproximadamente 6% no custo marginal de operação do sistema, de 7% no custo de operação, 1% na geração térmica total, além da estabilidade na geração hidráulica total e na energia armazenada. Vale ressaltar que estes resultados representam valores médios para todas as séries históricas de vazões, e para todos os meses do horizonte de estudo, ou seja, de abril de 2013 a dezembro de 2017.

Tabela 3 - Resultados Médios para a Configuração Default e para a Melhor Configuração de Faixas Operativas

	Default	750 Indivíduos	Varição
CMO (R\$/MWh)	174	163	-6,07%
Custo de Operação (R\$ *1000)	749.478	699.614	-6,65%
Energia Armazenada Final (MWhês)	181.841	181.456	-0,21%
Deficit (MWhês)	67	50	-25,81%
Geração Hidráulica (MWhês)	55.289	55.422	0,24%
Geração Térmica (MWhês)	8.113	8.039	-0,91%

6.3. Resultados com 4 Subsistemas

Uma vez que a plataforma de dados original do PMO de Abril de 2013 considera o sistema interligado nacional dividido em 4 subsistemas elétricos, o qual é utilizado pelo Operador Nacional do Sistema (ONS) para o planejamento

energética de médio prazo no Brasil, optou-se neste trabalho por se analisar os resultados do modelo SUIISHI também para esta configuração.

Devido ao maior custo computacional da execução de um caso com 4 subsistemas em relação à execução de um caso com 1 subsistema (9,5 vezes maior), as análises desta seção se resumiram à execução do modelo SUIISHI considerando-se a melhor configuração de faixas operativas encontrada nas análises para 1 subsistema, ou seja, aquela descrita na Tabela 1. Ou seja, o AG não foi executado para o caso com 4 subsistemas. As Figuras 19 a 27 mostram a evolução temporal dos resultados médios mensais para as mesmas variáveis apresentadas nas Figuras 13 a 18.




Figura 19 - Custo Total de Operação




Figura 20 - Custo Marginal de Operação do Sudeste




Figura 21 - Custo Marginal de Operação do Sul




Figura 22 - Custo Marginal de Operação do Nordeste




Figura 23 - Custo Marginal de Operação do Norte




Figura 24 - Energia Armazenada Final




Figura 25 - Déficit de Geração




Figura 26 - Geração Hidráulica Total




Figura 27 - Geração Térmica Total

De maneira análoga ao apresentado na seção 6.2, os resultados desta geração também mostram, em média, uma redução no custo de operação do sistema, no custo marginal de operação dos 4 subsistemas, no déficit de geração e na geração térmica total quando comparados aos resultados obtidos por meio da configuração default atualmente adotada no modelo SUIISHI. Ao mesmo tempo, níveis aproximadamente idênticos na energia armazenada final e na geração hidráulica total do sistema são observados. Os resultados da Tabela 4 corroboram com o descrito anteriormente, sendo observada uma redução média de aproximadamente 5% nos custos marginais de operação do Sul e do Sudeste, e de 4,4% no Norte e Nordeste, 6% no custo de operação do sistema, 1% na geração térmica total, 10% no déficit de geração, além de pequenos aumentos na geração hidráulica total e na energia armazenada do sistema. Assim como no caso com 1 subsistema, estes resultados representam valores médios para todas as séries históricas de vazões, e para todos os meses do horizonte de estudo.

Tabela 4 - Resultados Médios para a Configuração Default e para a Melhor Configuração de Faixas Operativas

	Default	750 Indivíduos	Variação
CMO Sudeste (R\$/MWh)	258	246	-4,78%
CMO Sul (R\$/MWh)	258	245	-4,98%
CMO Nordeste (R\$/MWh)	182	174	-4,40%
CMO Norte (R\$/MWh)	183	174	-4,42%
Custo de Operação (R\$ *1000)	1.065.391	1.004.617	-5,70%
Energia Armazenada Final (MWhês)	157.534	157.986	0,29%
Deficit (MWhês)	195	176	-9,54%
Geração Hidráulica (MWhês)	55.055	55.157	0,18%
Geração Térmica (MWhês)	8.164	8.091	-0,90%

7. Conclusões

Este trabalho teve como objetivo utilizar a meta-heurística conhecida como Algoritmos Genéticos para investigar a existência de configurações de faixas operativas alternativas à atualmente empregada pelo modelo SUSHI, que levassem a um menor custo de operação do sistema ao longo do horizonte de planejamento considerado.

Inicialmente foi realizada uma análise de sensibilidade considerando diferentes tamanhos de população para o AG. O objetivo foi determinar o impacto deste parâmetro na determinação da melhor solução, além de se determinar uma relação custo-benefício entre o aumento do custo computacional e a melhoria da qualidade da solução obtida. Para os tamanhos de população avaliados (100, 250, 500 e 750 indivíduos), a qualidade da solução foi maior quanto maior o tamanho da população, obtendo-se, para o caso com 750 indivíduos, uma solução com custo médio 6,65% menor do que o custo médio obtido com a utilização da configuração *default* das faixas operativas. Entretanto, cabe destacar que, em relação à solução obtida com 500 indivíduos na população, a redução de custo médio de operação foi de apenas 0,19%. Em contrapartida, foram necessárias 390 iterações adicionais para alcançar a convergência do AG.

Com o objetivo de se considerar a sensibilidade do especialista na operação do sistema, 4 indivíduos gerados de maneira exógena ao AG foram inseridos apenas na população inicial em cada uma das análises. Em todas as análises, o Indivíduo 4, previamente descrito na seção 4.3, representa uma das 6 melhores soluções da população inicial. Conclui-se desta análise que a inclusão deste indivíduo na população inicial contribui tanto para a qualidade da solução final quanto para a velocidade de convergência do algoritmo, tendo em vista a sua alta probabilidade de ser selecionada como um dos pais na geração de uma nova população. Adicionalmente, este fato pode indicar que, mesmo populações de 750 indivíduos, não são suficientes para representar

adequadamente o espaço de soluções do problema, ou mesmo que a geração aleatória de indivíduos para a população inicial não é a melhor estratégia para o problema proposto.

Analisando o comportamento médio de outras variáveis de interesse, tais como o custo marginal de operação, energia armazenada final, déficit de geração, geração hidráulica total e a geração térmica total, nota-se que a melhor solução encontrada leva à uma redução média de aproximadamente 6% no custo marginal de operação, de 7% no custo de operação, 1% na geração térmica total, além da estabilidade na geração hidráulica total e na energia armazenada.

A principal limitação para a continuidade das análises foi o alto custo computacional do processo de convergência do AG. Análises com populações superiores a 750 indivíduos são recomendadas para se determinar de maneira conclusiva a partir de que número de indivíduos o aumento da população não contribui significativamente para a redução do custo de operação.

Conforme mencionado na seção 6, o AG foi executado considerando a representação de apenas um subsistema elétrico no Brasil, quando, no caso oficial do PMO de Abril de 2013, o Operador Nacional do Sistema representa o Sistema Interligado Nacional dividido em 4 subsistemas. Sendo assim, recomenda-se a execução do AG com esta configuração.

Tanto para o aumento do número de indivíduos da população, quanto para a representação de 4 subsistemas elétricos, o elevado custo computacional destas análises representa um impeditivo para as mesmas. Por este motivo também se recomenda a utilização de técnicas de processamento paralelo para a utilização do AG ao problema proposto neste trabalho.

8. Bibliografia

- [1] M. Maceira, L. Terry, F. Costa, J. Damázio e A. Melo, **Chain of optimization models for setting the energy dispatch and spot price in the Brazilian system**, 14^o PSCC, Sevilla, 2002;
- [2] M. Maceira, V. Duarte, D. Penna, L. Moraes e A. Melo, **Ten years of application of stochastic dual dynamic in official and agent studies in Brazil description of the NEWAVE program**, Glasgow: 16th Power Systems Computation Conference, 2008.
- [3] F. Batista, M. Maceira, A. Marcato e V. Duarte, **Levantamento das Diferenças Numéricas e Metodológicas entre os Modelos NEWAVE e SUSHI**, XX SNPTEE, Recife, 2009.
- [4] J. Holland, **Adaptation in Natural and Artificial Systems**, University of Michigan Press, 1975.
- [5] Montesinos, F. G; Arnosó, J.; Vieira, R., 2005, **Using a Genetic Algorithm for 3-D Inversion of Gravity Data in Fuerteventura (Canary Islands)**, International Journal of Earth Sciences, vol. 94, issue 2, p.301–316.
- [6] Gavancho, K.S.; Pacheco, M.A., Hamacher, S. **Algoritmos Genéticos Aplicados à Seleção Multi-Critério de Carteiras de Projetos de Petróleo e Gás**, XXXIV Simpósio Brasileiro de Pesquisa Operacional, Novembro de 2002, Rio de Janeiro, Brasil.
- [7] Lazo, J.G.L.L., **Determinação do Valor de Opções Reais por Simulação Monte Carlo com Aproximação por Números Fuzzy e Algoritmos Genéticos**, Tese de Doutorado, Departamento de Engenharia Elétrica, Puc-Rio, 2004.

- [8] Orero, S.O.; Irving, M.R. **A Genetic Algorithm Modelling Framework and Solution Technique for Short Term Optimal Hydrothermal Scheduling.** IEEE Transactions on Power Systems. 2, Maio 1998, Vol. 13.
- [9] Kumar, B. R.; Murali. M.; Kumari, M.S.; Sydulu, M. **Short-range Fixed Head Hydrothermal Scheduling Using Fast Genetic Algorithm.** 7th IEEE Conference on Industrial Electronics and Applications. Julho de 2012, pp. 1313-1318.
- [10] Zoumas, C.E.; Bakirtzis; A.G; Theocharis, J.B.; Vasilios Petridis. **A Genetic Algorithm Solution Approach to the Hydrothermal Coordination Problem.** IEEE Transactions on Power Systems. 3, 2004, Vol. 19.
- [11] Ferreira, V. H.; Silva, G. H. C. **Natural optimization applied to medium-term hydrothermal coordination.** *16th Intelligent System Application to Power Systems (ISAP).* 2011, pp. 1-6.
- [12] Leite, P.T., Carneiro, A.A.F.M.; Carvalho, A.C.P.L.F. **Energetic operation planning using genetic algorithms.** *IEEE Transactions on Power Systems.* 1, 2002, Vol. 17.
- [13] Linden, R., **Algoritmos Genéticos**, 3^a edição, ed. Ciência Moderna, Rio de Janeiro, 2012.