

NÁTALLI MACEDO RODRIGUES

**UM ALGORITMO CULTURAL PARA PROBLEMAS DE
DESPACHO DE ENERGIA ELÉTRICA**

MARINGÁ

2007

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Catálogo na Publicação
Fabiano de Queiroz Jucá – CRB 9/1249
Biblioteca Central da UNICENTRO, Campus Guarapuava

R696a Rodrigues, Nátalli Macedo
Um algoritmo cultural para problemas de despacho de energia elétrica / Nátalli Macedo Rodrigues. -- Maringá, 2007.
xix, 79 f. : 28 cm

Dissertação (Mestrado) - Universidade Estadual de Maringá,
Programa de Pós-Graduação em Ciência da Computação, 2007

Orientador: Ademir Aparecido Constantino

Banca examinadora: Ademir Aparecido Constantino, Márcia
Marcondes Altimari Samed, Myriam Regattieri De Biase da Silva
Delgado

Bibliografia

1. Algoritmo cultural. 2. Algoritmo genético. 3. Despacho
ambiental. 4. Despacho econômico. I. Título. II. Universidade Estadual
de Maringá.

CDD 005.1

NÁTALLI MACEDO RODRIGUES

**UM ALGORITMO CULTURAL PARA PROBLEMAS DE
DESPACHO DE ENERGIA ELÉTRICA**

Dissertação apresentada ao Programa de
Pós-Graduação em Ciência da Computação
da Universidade Estadual de Maringá, como
requisito parcial para obtenção do grau de
Mestre em Ciência da Computação.

Orientador: Prof. Dr. Ademir Aparecido
Constantino

MARINGÁ

2007

requisito parcial para obtenção do grau de

Universidade Estadual de Maringá – DAIN/DEMI



Profa. Dra. Myriam Regatieri De Biase da Silva Delgado
Universidade Tecnológica Federal do Paraná – DAIN/UTFPR

"Aqueles que se apaixonam
pela prática sem a teoria
são como navegadores sem timão
ou bússola, nunca sabem
aonde vão parar."
-Leonardo da Vinci

"Se a princípio uma idéia não é absurda,
então não existe a menor esperança para ela"
-Albert Einstein

Dedico esta dissertação ao meu pai.
Tenho certeza que, esteja onde estiver,
ele sempre está torcendo por mim.
Sem essa certeza seria impossível viver.

Agradecimentos

Ao meu orientador e professor Dr. Ademir Aparecido Constantino pela confiança depositada em mim na escolha do tema e pela sua orientação.

A professora Dra. Márcia Marcondes Altimari Samed pelos muitos conselhos, dicas e orientações ao longo do trabalho que me proporcionaram chegar a conclusão do mesmo.

A todos os professores do programa que de alguma forma contribuíram para a realização desse trabalho.

A Inês que sempre foi tão prestativa.

Agradeço especialmente a minha mãe, que é uma guerreira, pelo total apoio em todos os momentos da minha vida. Sem o seu amor, compreensão e ajuda financeira eu não teria chegado até aqui.

A minha irmã Núbbya por sua compreensão e amor em todos os momentos em que preciso me fazer ausente para continuar minha caminhada. E, principalmente, por estar sempre presente me dando apoio e a sua mão amiga tanto nos momentos difíceis quanto os de felicidade.

A minha irmã Fabiana pela confiança em mim depositada. Mesmo longe, ela sabe se fazer presente sempre, dando suporte emocional e muita força.

Aos amigos e irmãos de coração mais que especiais Carola e Richard. Sem a ajuda, acolhida, sorvetes, risadas e cama dividida, esse trabalho não teria sido concluído satisfatoriamente. Minha eterna gratidão.

Ao Pará e Luciano pela acolhida carinhosa, passeios e filmes em todas as minhas viagens.

A uma pessoa especial que vem fazendo parte da minha vida nos últimos meses pelos puxões de orelha, colo, compreensão e carinho nos momentos em que mais preciso.

Aos amigos, tanto os que estão perto quanto os que estão distantes, que sempre me dão apoio, amor, carinho e confiam no meu potencial. Essa ajuda é que me faz

continuar minha caminhada apesar dos obstáculos.

As pessoas mais que amadas na minha vida, que não cabe aqui citar seus nomes. Estão sempre ao meu lado nos momentos em que eu mais preciso. Me dão força para que eu tenha coragem de enfrentar os desafios da vida. São mãos que me sustentam, que me batem e afagam. Sem eles certamente eu não seria completa e a vida não seria feliz.

Aos professores do Departamento de Ciência da Computação da Unicentro, que antes eram professores e agora são colegas e amigos, por terem sido tão compreensivos em todas as vezes que precisei me ausentar do trabalho.

A minha grande família de Campo Grande que está sempre mandando vibrações positivas e torce muito para o meu sucesso.

A Deus por ter me dado a vida e ter aberto tantas portas em minha jornada.

A todos que de alguma forma, contribuíram para a realização desse trabalho.

“As pessoas entram em nossa vida por acaso,
mas não é por acaso que elas permanecem”.

Lista de Algoritmos

1	Algoritmo Genético	p. 15
2	Algoritmo Cultural (REYNOLDS, 2003)	p. 27
3	Algoritmo Cultural Implementado	p. 37
4	Atualização do Conhecimento Situacional	p. 44
5	Atualização do Conhecimento Normativo	p. 47

Sumário

Lista de Figuras	p. xiii
Lista de Tabelas	p. xv
Lista de Algoritmos	p. xvii
Lista de Abreviaturas e Siglas	p. xvii
Resumo	p. xvii
Abstract	p. xvii
1 Introdução	p. 1
1.1 Motivação	p. 2
1.2 Justificativa	p. 3
1.3 Objetivos	p. 3
1.4 Organização do Trabalho	p. 3

2	Despacho Econômico/Ambiental	p. 5
2.1	Despacho Econômico	p. 5
2.1.1	Modelo Matemático do Despacho Econômico	p. 6
2.2	Despacho Ambiental	p. 8
2.3	Despacho Econômico/Ambiental	p. 9
2.3.1	Conceitos de Dominância de Pareto	p. 10
	Conceito de Inferioridade	p. 10
	Conceito de Superioridade	p. 10
	Conceito de Não-Inferioridade	p. 10
2.4	Trabalhos Correlatos	p. 11
3	Algoritmos Genéticos	p. 13
3.1	Representação dos Indivíduos	p. 15
3.2	Operadores Genéticos	p. 16
3.2.1	Cruzamento	p. 16
	Cruzamento de 1-Ponto e N-Pontos	p. 16
	Cruzamento Uniforme	p. 17
	Cruzamento Média	p. 17
3.2.2	Mutação	p. 18
3.3	Métodos de Seleção	p. 18
3.4	Elitismo	p. 20
3.5	Função de Aptidão	p. 20

3.6 População Inicial	p. 20
3.7 Critérios de Parada	p. 21
3.8 Parâmetros	p. 22
3.9 Trabalhos Correlatos	p. 22
4 Algoritmos Culturais	p. 24
4.1 Inspiração Natural	p. 24
4.2 Funcionamento Básico de um Algoritmo Cultural	p. 25
4.3 Principais Características	p. 28
4.4 Micro Evolução x Macro Evolução	p. 29
4.4.1 Espaço Populacional	p. 29
4.4.2 Espaço de Crenças	p. 29
4.4.3 Protocolos de Comunicação	p. 30
Função de Aceitação	p. 30
Função de Influência	p. 30
4.4.4 Tipos de Conhecimento	p. 31
Conhecimento Situacional	p. 31
Conhecimento Normativo	p. 31
Conhecimento do Domínio	p. 32
Conhecimento Topográfico	p. 32
Conhecimento Histórico	p. 33
4.5 Trabalhos Correlatos	p. 34

5 Metodologia Proposta	p. 36
5.1 Modelo Computacional Desenvolvido	p. 37
5.1.1 Criação do Espaço de Crenças, Inicialização e Avaliação da População	p. 39
5.1.2 Seleção dos Pais	p. 40
5.1.3 Geração e Seleção de Indivíduos e Atualização do Espaço de Crenças	p. 41
5.2 Espaço Populacional	p. 41
5.3 Espaço de Crença	p. 42
5.4 Tipos de Conhecimento	p. 43
5.4.1 Conhecimento Situacional	p. 44
Função de Influência do Conhecimento Situacional na Mutação	p. 45
Função de Influência do Conhecimento Situacional no Cruzamento	p. 46
5.4.2 Conhecimento Normativo	p. 46
Função de Influência do Conhecimento Normativo na Mutação	p. 48
Função de Influência do Conhecimento Normativo no Cruzamento	p. 49
5.4.3 Conhecimento Situacional/Normativo	p. 50
Função de Influência do Conhecimento Situacional/Normativo na Mutação	p. 50
Função de Influência do Conhecimento Situacional/Normativo no Cruzamento	p. 51
5.5 Adaptação dos Parâmetros	p. 52
6 Simulações e Resultados	p. 56
6.1 Despacho Econômico	p. 57

6.1.1 Caso 3 Geradores	p. 57
6.1.2 Caso 13 Geradores	p. 61
6.2 Despacho Econômico/Ambiental	p. 66
6.2.1 Caso 6 Geradores	p. 66
7 Conclusões e Trabalhos Futuros	p. 74
7.1 Conclusões	p. 74
7.2 Trabalhos Futuros	p. 75
Referências Bibliográficas	p. 76

Lista de Figuras

2.1	Curva típica de entrada-saída de uma unidade térmica	p. 7
3.1	Cruzamento 1-ponto	p. 17
3.2	Reprodução de 2-pontos	p. 17
3.3	Mutação Clássica	p. 18
3.4	Desempenho de um AG com e sem Elitismo	p. 20
4.1	Funcionamento Básico de um Algoritmo Cultural.	p. 27
4.2	Representação de Conhecimento Situacional (IACOBAN; REYNOLDS; BREWSTER, 2003b).	p. 31
4.3	Representação de Conhecimento Normativo (IACOBAN; REYNOLDS; BREWSTER, 2003b).	p. 32
4.4	Representação de Conhecimento Topográfico (BECERRA; COELLO, 2005).	p. 33
4.5	Representação de Conhecimento Histórico (BECERRA; COELLO, 2005).	p. 34
5.1	Diagrama Esquemático dos passos do Algoritmo Cultural Desen- volvido.	p. 38

6.1	Caso 3 Geradores - Gráfico da média inicial de custo do melhor indivíduo.	p. 60
6.2	Caso 3 Geradores - Gráfico dos melhores custos do melhor indivíduo.	p. 60
6.3	Caso 3 Geradores - Gráfico do início da evolução dos operadores de Mutação e Cruzamento.	p. 61
6.4	Caso 3 Geradores - Gráfico do início da evolução dos Conhecimentos.	p. 61
6.5	Caso 13 Geradores - Gráfico da média inicial de custo do melhor indivíduo.	p. 64
6.6	Caso 13 Geradores - Gráfico dos melhores custos do melhor indivíduo.	p. 65
6.7	Caso 13 Geradores - Gráfico do início da evolução dos operadores de Mutação e Cruzamento.	p. 65
6.8	Caso 13 Geradores - Gráfico do início da evolução dos Conhecimentos.	p. 65
6.9	Caso 6 Geradores - alfa 0.0 - Gráfico da média de custo.	p. 70
6.10	Caso 6 Geradores - alfa 0.0 - Gráfico da média de emissões.	p. 70
6.11	Caso 6 Geradores - alfa 0.0 - Gráfico dos melhores custos.	p. 71
6.12	Caso 6 Geradores - alfa 0.0 - Gráfico das melhores emissões.	p. 71
6.13	Caso 6 Geradores - alfa 0.0 - Gráfico da evolução dos operadores de Mutação e Cruzamento.	p. 72
6.14	Caso 6 Geradores - alfa 0.0 - Gráfico do início da evolução dos Conhecimentos.	p. 72
6.15	Aproximação da Fronteira de Pareto Obtida pelo AC.	p. 73
6.16	Aproximação da Fronteira de Pareto Obtida pelo AGHCOE.	p. 73

Lista de Tabelas

6.1	Características do Sistema - Caso 3 Geradores	p. 58
6.2	Resultados Obtidos pelo AC - Caso 3 Geradores	p. 58
6.3	Alocação das Potências - Caso 3 Geradores	p. 59
6.4	Melhor Valor de Custo Obtidos pelos AGs e pelo AC - Caso 3 Geradores	p. 59
6.5	Características do Sistema - Caso 13 Geradores	p. 62
6.6	Resultados Obtidos pelo AC - Caso 13 Geradores	p. 62
6.7	Alocação das Potências - Caso 13 Geradores	p. 63
6.8	Melhor Valor de Custo - Caso 13 Geradores	p. 63
6.9	Comparação dos Melhores Custos Obtidos pelo AC e pelo GA+GE+AT - Caso 13 Geradores	p. 64
6.10	Características do Sistema - Caso 6 Geradores	p. 66
6.11	Limites Operacionais - Caso 6 Geradores	p. 67
6.12	Resultados Obtidos pelo AC - Caso 6 Geradores	p. 67
6.13	Alocação das Potências pelo AGHCOE - Caso 6 Geradores - DEA	p. 68

6.14 Alocação das Potências pelo AC - Caso 6 Geradores - DEA	p. 68
6.15 Custo e Emissão do AGHCOE e do AC - Caso 6 Geradores - DEA	p. 69
6.16 Valor da Função Objetivo do AGHCOE e do AC - Caso 6 Geradores - DEA	p. 69

Resumo

Este trabalho tem por objetivo apresentar a implementação de um Algoritmo Cultural que resolve Problemas de Despacho, em particular o Despacho Econômico, Despacho Ambiental e Despacho Econômico/Ambiental. O Algoritmo Cultural é uma metaheurística evolutiva baseada no processo de evolução cultural da humanidade. Essa evolução é baseada na forma como o ser humano adquire e dissemina sua cultura (conhecimentos) com o passar das gerações. O Algoritmo Cultural é um método híbrido por definição, sendo que nesse trabalho ele foi hibridizado com um método bastante conhecido: o Algoritmo Genético, o qual se inspira na teoria da evolução das espécies. Ao final do trabalho tem-se a comparação dos resultados obtidos com o algoritmo implementado e os resultados encontrados na literatura. O caso de usinas termoeletricas de três e treze geradores de energia foi utilizado para o estudo do comportamento do Despacho Econômico. Já o Despacho Ambiental e o Despacho Econômico/Ambiental foram testados em um caso com seis geradores. Os resultados obtidos pelo algoritmo implementado são comparáveis aos melhores valores publicados na literatura e, em alguns casos, são até mesmo superiores.

Palavras-chaves: Despacho Econômico, Despacho Ambiental, Algoritmos Genéticos, Algoritmos Culturais.

Abstract

This work intends to present the implementation of a Cultural Algorithm to solve Dispatch Problems, specifically Economic Dispatch, Environmental Dispatch and Economic/Environmental Dispatch. The Cultural Algorithm is an evolutionary metaheuristic based on human culture evolution process. This evolution is based on the form that one acquires and spreads one's cultures (knowledge) across generations. The Cultural Algorithm is a hybrid method by definition. In this work it is hybridized with a very known method: the Genetic Algorithm, which is based upon the theory of the evolution of the species. At the end of the work is presented a comparison of the results gotten with the implemented algorithm and the results found in literature. The case of thermoelectrical factory with three and thirteen energy generating units was used for the study of the behavior of the Economic Dispatch. The Environmental Dispatch and the Economic/Environmental Dispatch was tested in a case with six units. The results obtained with the CA algorithm are comparable to the best published values found in literature and, in some cases, they are even better.

Keywords: Economic Dispatch, Environmental Dispatch, Genetic Algorithm, Cultural Algorithm.

Capítulo**1*****Introdução***

O termo problemas de otimização é freqüentemente visto nas áreas de engenharia e de tecnologia, que possui um significado físico em que a solução deve satisfazer as restrições do problema descrito tanto para maximizar quanto para minimizar uma função objetivo.

Em engenharia, métodos de otimização podem ser utilizados para se obter melhores resultados em problemas de programação não-linear, entre outros.

Um método de otimização que seja operacionalmente eficaz para resolver problemas de programação não-linear deve ser capaz de fornecer um conjunto de soluções melhores do que as já existentes, aliadas à flexibilidade e facilidade de adaptação a novas situações.

Há várias aplicações de otimização em problemas de programação não-linear na engenharia. Um exemplo dessa classe de problemas é o problema do Despacho de Energia Elétrica, que pode ser dividido em diferentes tipos, como é o caso do Despacho Econômico, o Despacho Ambiental e o Despacho Econômico/Ambiental.

Em geral, o principal objetivo desse problema é encontrar o valor ótimo de

energia que deve ser produzida em cada um dos geradores em questão de forma que se tenha um custo e/ou emissão de poluentes minimizados.

Desde a sua formulação até os dias de hoje, o problema do Despacho tem sido bastante estudado para que se encontrem avanços nos métodos de otimização empregados na sua resolução.

Nos dias de hoje, métodos heurísticos têm sido empregados na resolução de problemas de otimização, já que esses são capazes de fornecer soluções aceitáveis ou até melhores do que as soluções já conhecidas para esses problemas em tempo de processamento aceitável.

Um exemplo de método heurístico bastante recente é o método evolutivo conhecido como Algoritmo Cultural, que além de ser baseado na evolução fenotípica de determinados indivíduos (conhecimento), utiliza essas características para guiar a evolução genética das populações futuras. A evolução genética é dada por qualquer método que faça uso de população, como é o caso dos algoritmos de Evolução Diferencial, Programação Evolutiva, Programação Genética, *Particle Swarm* e os Algoritmos Genéticos.

Foi proposto para esse trabalho, um Algoritmo Cultural que utiliza um Algoritmo Genético na evolução genética para resolver problemas de Despacho Econômico/Ambiental. O Algoritmo Genético foi escolhido por ser o método evolutivo utilizado por (SAMED, 2004), que a priori foi considerado para comparação de resultados.

1.1 Motivação

Como já visto, o problema do Despacho é de suma importância, não apenas por trazer benefícios como a diminuição de custos mas por também tentar reduzir a emissão de poluentes no meio ambiente, já que essa emissão causa, entre outros problemas, o efeito estufa.

Métodos de otimização que ajudem na resolução desse problema são sempre importantes, principalmente se os métodos propostos forem capazes de produzir resultados melhores que os encontrados até o momento.

Por todos esses pontos, foi escolhido para resolver o problema supra citado um

Algoritmo Cultural, que além de ser uma técnica relativamente nova, acredita-se ainda que seja capaz de encontrar valores melhores que as técnicas heurísticas tradicionais por ser baseada na evolução cultural da população.

1.2 Justificativa

O método implementado foi escolhido por ser um método que vem sendo aplicado com bastante sucesso em problemas de otimização convexa, principalmente problemas de otimização com restrições, que é o caso do problema do Despacho Econômico, Ambiental e Econômico/Ambiental.

1.3 Objetivos

O objetivo desse trabalho é a implementação de um Algoritmo Cultural capaz de resolver problemas de Despacho de forma eficiente e que contribui significativamente no processo de otimização de geração de energia.

Para isso, desenvolveu-se neste trabalho um Algoritmo Cultural o qual faz uso de um Algoritmo Genético em seu espaço populacional e que armazena três tipos de conhecimentos. São eles: Conhecimento Situacional, Conhecimento Normativo e Conhecimento Situacional/Normativo. Cada um desses conhecimentos é responsável por influenciar os operadores genéticos de mutação e cruzamento na geração de novos indivíduos.

Os resultados obtidos com esse trabalho serão comparados com os resultados do trabalho de (SAMED, 2004), (KIM et al., 2002) e (SHEBLE; BRITTIG, 1995).

1.4 Organização do Trabalho

Esta dissertação está dividida em seis capítulos. O Capítulo 2 descreve os problemas de Despacho Econômico e Despacho Ambiental e o modelo de representação desses problemas. No Capítulo 3 são apresentados os principais conceitos de Algoritmos Genéticos. Já o Capítulo 4 apresenta uma descrição dos Algoritmos Culturais.

O Capítulo 5 demonstra a metodologia utilizada no desenvolvimento dos algoritmo proposto. As simulações computacionais e a discussão dos resultados são apresentados no Capítulo 6. Por fim, são apresentadas as conclusões e sugestões para trabalhos futuros no Capítulo 7.

Despacho Econômico/Ambiental

Nas seções seguintes serão apresentados os conceitos básicos e definições relacionadas ao Despacho Econômico, Despacho Ambiental e sobre a abordagem que visa resolver os dois problemas de uma só vez, o Despacho Econômico/Ambiental.

2.1 Despacho Econômico

A função básica dos sistemas elétricos é gerar com custo mínimo a demanda de energia a fim de suprir as necessidades dos consumidores, sendo que essa geração de energia deve ser da forma mais confiável e econômica possível (TAKAHASHI, 2004).

O Despacho Econômico pode ser considerado um problema genérico que aparece geralmente como um sub-problema de problemas maiores, como é o caso do *Unit Commitment*, Fluxo de Potência Ótimo, Despacho de Geração Ativa, entre outros (SILVA; NEPOMUCENO; BASTOS, 2004).

O Despacho Econômico é o estudo da alocação ótima de uma demanda entre as unidades geradoras de um sistema de geração termoeletrica. Este problema possui o

objetivo de minimizar o custo de produção de energia elétrica através da otimização da distribuição da produção entre os geradores e da utilização eficiente dos recursos energéticos.

Além desse objetivo, é indispensável que as condições de operação do sistema sejam satisfeitas. Como resultado da satisfação dos objetivos, obtêm-se as potências ótimas de saída de cada uma das unidades geradoras de energia consideradas. A função custo total da geração é obtida através da soma de cada uma das unidades geradoras.

Novos trabalhos e ferramentas para auxiliar a tomada de decisão em relação ao Despacho Econômico são desenvolvidos com frequência, demonstrando a importância do problema e a necessidade de se melhorar as ferramentas e trabalhos atuais.

2.1.1 Modelo Matemático do Despacho Econômico

O modelo matemático que rege o problema do Despacho Econômico se dá através da seguinte formulação:

$$\min Fe \tag{2.1}$$

Sujeito a:

$$\begin{aligned} \sum_{i=1}^n P_i &\geq P_D \\ P_i^{min} &\leq P_i \leq P_i^{max} \end{aligned} \tag{2.2}$$

em que Fe é a função custo total de geração do Despacho Econômico, P_i corresponde à potência de saída do i -ésimo gerador, P_i^{max} e P_i^{min} representam, respectivamente, as potências máximas e mínimas de geração de cada unidade geradora e P_D é o valor da demanda de energia.

O custo total da geração termoelétrica é obtido através de uma função quadrática

aplicada a cada uma das unidades geradoras de energia, como mostra a Equação 2.3.

$$Fe = \sum_{i=1}^n Fe_i(P_i) = \sum_{i=1}^n a_i P_{Gi}^2 + b_i P_{Gi} + c_i \quad (2.3)$$

em que Fe_i representa os custos de cada unidade geradora i , P_i é a potência de saída do i -ésimo gerador e a_i , b_i e c_i são os coeficientes característicos da função custo.

O custo das unidades geradoras é dado por uma curva característica de entrada-saída, como mostra a Figura 2.1. Uma curva de entrada-saída idealizada pode ser aproximada por uma expressão não-linear, convexa e suave, como sugere a equação 2.3 (SAMED; RAVAGNANI; GOMES, 2003):

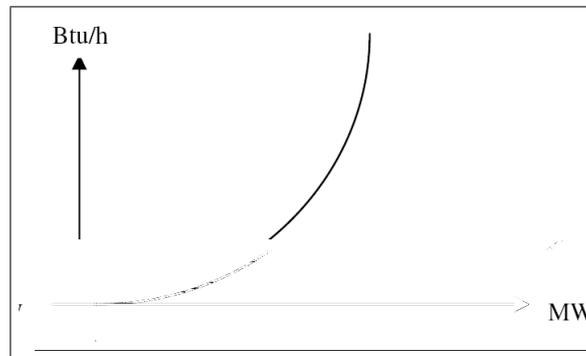


Figura 2.1: Curva típica de entrada-saída de uma unidade térmica (SAMED; RAVAGNANI; GOMES, 2003).

No entanto, uma formulação mais rigorosa para o Despacho Econômico é denominada Despacho Econômico com efeito do ponto de válvula e pode ser modelada conforme a equação 2.4:

$$\min Fe = \sum_{i=1}^n Fe_{pV_i} = \sum_{i=1}^n a_i P_i^2 + b_i P_i + c_i + |d_i \text{sen}(e_i(P_i^{\min} - P_i))| \quad (2.4)$$

em que Fe_{pV_i} representa os custos de cada unidade geradora i considerando o efeito do ponto de válvula, a_i , b_i , c_i , d_i e e_i são os coeficientes característicos da função custo considerando o efeito do ponto de válvula.

A seguir, serão apresentados os conceitos sobre uma outra abordagem do Problema do Despacho, que é o Despacho Ambiental.

2.2 Despacho Ambiental

O objetivo do Despacho Ambiental é encontrar os níveis mínimos de concentração que resultam da relação entre a quantidade de cada poluente e a saída de potência dos geradores para satisfazer uma determinada demanda.

A função objetivo é dada por uma função polinomial de segunda ordem, conforme a Equação 2.5 (SAMED, 2004):

$$Fa_i(P_i) = A_i P_i^2 + B_i P_i + C_i \quad (2.5)$$

em que Fa_i é a função emissão, P_i é a potência de saída do i -ésimo gerador e A_i , B_i e C_i são os coeficientes da função emissão.

As emissões totais são obtidas através do somatório das emissões em cada um dos geradores, como segue:

$$Fa = \sum_{i=1}^n Fa_i(P_i) \quad (2.6)$$

Sendo que Fa é a função emissão total.

Como dito anteriormente, no problema do Despacho Ambiental se tem por objetivo a minimização de emissão de poluentes no meio ambiente. As restrições a serem satisfeitas são as mesmas do problema do Despacho Econômico. O modelo de otimização do Despacho Ambiental e as suas restrições são dados pelas Equações 2.7 e 2.8 a seguir:

$$\min Fa \quad (2.7)$$

Sujeito a

$$\begin{aligned} \sum_{i=1}^n P_i &\geq P_D \\ P_i^{min} &\leq P_i \leq P_i^{max} \end{aligned} \quad (2.8)$$

em que Fa é a função emissão total de geração do Despacho Ambiental, P_i representa a potência de saída do i -ésimo gerador e P_D representa a demanda.

2.3 Despacho Econômico/Ambiental

As usinas termoelétricas geralmente se baseiam apenas na estratégia do Despacho Econômico, a fim de obter uma minimização do custo de produção de energia. Porém, a queima de combustíveis fósseis como o carvão, óleo e gás, ou a combinação destes emitem na atmosfera muitos poluentes que são prejudiciais não só para os seres humanos como para os animais e plantas (SAMEDI; RAVAGNANI; GOMES, 2003). Existem duas maneiras de se minimizar essas emissões na atmosfera. Uma delas é a instalação de sistemas de purificação pós-combustão com precipitadores eletrostáticos. Outra forma é minimizar as emissões através de estratégia de Despacho.

Essa segunda estratégia combina o custo de combustível e emissão de poluentes em uma função simples com o ajuste de diferentes pesos e é chamada de Despacho Econômico/Ambiental (DEA).

Como custo e emissão são objetivos conflitantes, não se pode obter a minimização de ambos simultaneamente. Por isso são utilizados diferentes pesos atribuídos a cada um dos objetivos, para que determinadas exigências sejam satisfeitas para diferentes situações.

Um modelo de otimização multi-objetivo para o Despacho Econômico Ambiental é dado por:

$$\min[\alpha Fe(P_i) + (1 - \alpha) Fa(P_i)] \quad (2.9)$$

Sujeito a

$$\begin{aligned} \sum_{i=1}^n P_i &\geq P_D \\ P_i^{min} &\leq P_i \leq P_i^{max} \end{aligned} \quad (2.10)$$

em que α pode assumir qualquer valor no intervalo $[0,1]$.

Quando α assume o valor 0, implica em emissões mínimas, ou seja, Despacho Ambiental. Analogamente, quando α assume o valor 1, implica em custo mínimo, ou seja, Despacho Econômico.

2.3.1 Conceitos de Dominância de Pareto

Como o problema do Despacho Econômico/Ambiental é um problema multi-objetivo, a sua solução não corresponde a apenas um ponto e sim a um conjunto de pontos que são denominados Ótimos de Pareto ou soluções não-dominadas. Esse conceito foi formulado por Vilfredo Pareto no século XIX e se deu início as pesquisas envolvendo otimização multi-objetivo.

A seguir serão definidos alguns conceitos essenciais na otimização de Pareto (SAMED, 2004).

Conceito de Inferioridade

Um vetor $a = (a_1, a_2, \dots, a_n)$ é dito ser inferior a $b = (b_1, b_2, \dots, b_n)$ se e somente se, $\forall i = 1, 2, \dots, n, a_i \leq b_i$ existe pelo menos uma dimensão j em que a_j é estritamente menor que b_j ($a_j < b_j$).

Conceito de Superioridade

Um vetor $a = (a_1, a_2, \dots, a_n)$ é dito superior a $b = (b_1, b_2, \dots, b_n)$ se e somente se b for inferior ao vetor a .

Conceito de Não-Inferioridade

Dois vetores a e b são ditos não-inferiores se a não é superior nem inferior a b . O conceito de não inferioridade pode ser descrito da seguinte forma:

Sejam dois candidatos a e b , para algum objetivo i $f_i(a) \leq f_i(b)$, e para pelo menos um objetivo j , $f_j(a) \geq f_j(b)$.

As soluções Pareto-Ótimo são as soluções em que o espaço de busca cujo vetor correspondente em \wedge não pode ser simultaneamente melhorado, isto é, qualquer melhoria em um componente é acompanhada por uma degradação em pelo menos um outro. Essas soluções são conhecidas também por soluções não-inferiores.

2.4 Trabalhos Correlatos

Em (SONG et al., 1997) é apresentado um Algoritmo Genético controlado por Lógica Nebulosa para os problemas de Despacho Econômico e Ambiental. Esse Algoritmo Genético é composto por dois controladores nebulosos baseados em algumas heurísticas de ajuste adaptável de probabilidades de cruzamento e taxa de mutação durante o processo de otimização. Os resultados dessa abordagem foram comparados com os resultados obtidos por um AG convencional e um método de Newton-Raphson. Os resultados foram encorajadores.

Já em (WONG; YURYEVICH, 1998) foi apresentado um algoritmo baseado em Programação Evolutiva para resolver o problema do Despacho Econômico com Restrições Ambientais. Nesse algoritmo são usadas técnicas de aceleração de soluções capazes de realçar a velocidade e robustez do algoritmo.

No trabalho de (PÉREZ-GUERRERO; CEDEÑO-MALDONADO, 2005) é apresentada uma solução para o problema do Despacho Econômico/Ambiental por um algoritmo de Evolução Diferencial. Essa técnica foi escolhida por se tratar de um problema complexo e altamente não-linear. A validação desse algoritmo foi feita utilizando o sistema *IEEE 30 barras*. Os resultados obtidos comprovaram a eficácia do modelo proposto.

Em (MOHAMMADI; VARAHRAM, 2006) são comparados dois métodos que resolvem o problema do Despacho Econômico/Ambiental. Os métodos comparados foram uma Rede Neural de Hopfield e o Método de Iteração λ . Os casos considerados para comparação são os de 3, 6 e 20 geradores. Constatou-se que a Rede Neural foi mais eficiente tanto em tempo de execução quanto em tempo de convergência.

No trabalho de (ZHANG et al., 2006) é proposto um Algoritmo Genético Híbrido com técnicas quasi-simplex que resolvem o modelo de Despacho Econômico Dinâmico com função de custo e restrições não suaves. É sugerida uma maneira de geração da população inicial para acelerar o processo de busca. Os casos de despacho considerados para validar o modelo e o algoritmo foram os de 13 e 24 geradores. Após os testes e resultados, tanto modelo quanto algoritmo foram validados e considerados eficientes.

Algoritmos Genéticos

Os Algoritmos Genéticos (AGs) são algoritmos estocásticos de busca inspirados no comportamento das espécies na natureza (COELHO, 2003). O motivo da inspiração na natureza é que esta consegue resolver satisfatoriamente problemas altamente complexos (como a sobrevivência das espécies, por exemplo).

Algoritmos de busca são aqueles que percorrem um determinado espaço de possíveis soluções em busca de uma solução ótima ¹ para o problema. Já algoritmos estocásticos são algoritmos não-determinísticos baseados em princípios estatísticos, ou seja, eles percorrem o espaço de possíveis soluções de maneira estocástica (aleatória).

Basicamente os AGs tratam da simulação da evolução de estruturas individuais (cromossomos), via processo de seleção e os operadores de busca, chamados operadores genéticos (mutação e cruzamento). Este processo depende da aptidão atingida pelas estruturas individuais, frente a um ambiente. A seleção é focalizada nos indivíduos com um alto grau de aptidão, explorando a informação da aptidão disponível. O cruzamento e a mutação perturbam estes indivíduos (heurística geral

¹Apesar de procurar pela solução ótima, algumas vezes os algoritmos de busca encontram apenas boas soluções (factíveis).

para a exploração).

Os AGs foram desenvolvidos por John Holland e alguns de seus colaboradores da *University of Michigan* quando estes compreenderam que os mecanismos biológicos permitiam a adaptação do sistema natural biológico de forma que poderiam ser expressas matematicamente e simuladas computacionalmente (WHITLEY, 1998) (WHITLEY, 2001) (GOLDBERG, 1989). A idéia de Holland foi tentar imitar algumas etapas do processo da evolução natural das espécies incorporando-as a um algoritmo computacional. O ponto de referência foi gerar a partir de uma população de cromossomos, novos cromossomos com propriedades genéticas superiores às de seus antecedentes (COELHO, 2003).

Um AG é basicamente projetado conforme as seguintes etapas:

1. Geração da população inicial de cromossomos que consiste de um conjunto de possíveis soluções para o problema a ser resolvido. Essa população é geralmente gerada de forma aleatória;
2. A população é avaliada (de acordo com uma função chamada função de aptidão) e cada cromossomo recebe um valor que reflete sua qualidade para resolução do problema;
3. Depois de avaliados, os indivíduos passam por um processo de seleção onde os indivíduos mais aptos são selecionados e os menos aptos são descartados;
4. São aplicados os operadores genéticos nos cromossomos selecionados. Os operadores genéticos mais conhecidos são o de cruzamento e o de mutação;
5. Uma nova geração de soluções é obtida contendo os descendentes gerados pelas modificações realizadas na etapa 4;
6. As etapas de 2 a 5 são repetidas até que seja encontrada uma solução satisfatória.

As etapas mencionadas podem ser melhor entendidas através de um algoritmo, mostrado a seguir (LACERDA; CARVALHO, 1999):

Algoritmo 1 Algoritmo Genético

Algoritmo GenéticoSeja $S(t)$ a população de cromossomos na geração t $t \leftarrow 0$ Inicializar $S(t)$ Avaliar $S(t)$ **Enquanto** (!Condição de Parada()) **faça** $t \leftarrow t+1$ Selecionar $S(t)$ a partir de $S(t-1)$ Aplicar reprodução em $S(t)$ Aplicar mutação em $S(t)$ Avaliar $S(t)$ **fim enquanto**

Nas seções seguintes serão apresentados os principais conceitos de um Algoritmo Genético.

3.1 Representação dos Indivíduos

A população de um AG é formada por indivíduos. A representação desses indivíduos define como a estrutura será manipulada. Essa representação depende do tipo de problema a ser resolvido. Os principais tipos de representação são a binária, real, permutação inteira e simbólica.

A representação binária é utilizada para problemas inteiros e numéricos, sendo que os problemas numéricos também podem fazer uso de representação real. Já a representação de permutação de símbolos é recomendada para ser utilizada em problemas baseados em ordem (como, por exemplo, *job shop scheduling*, caixeiro viajante, entre outros). Para problemas de agrupamento (*clustering*) é utilizada a representação baseada em itens repetidos.

Os indivíduos representam os parâmetros da função objetivo que será maximizada ou minimizada.

Neste trabalho foi utilizada a codificação real para a representação dos indivíduos.

3.2 Operadores Genéticos

Os operadores genéticos são responsáveis por modificar a população de alguma maneira, de forma a explorar regiões desconhecidas do espaço de busca a fim de encontrar regiões com melhores soluções (WHITLEY, 1998) (COELHO, 2003).

Existem vários tipos de operadores, sendo que alguns deles são utilizados em implementações específicas. Os operadores que usualmente são mais utilizados são o de Cruzamento e o de Mutação.

A seguir, esses dois tipos de operadores serão descritos mais detalhadamente.

3.2.1 Cruzamento

O funcionamento desse operador consiste basicamente em combinar informações de dois quaisquer indivíduos da população, a fim de que se tenham dois novos indivíduos com características melhores que a dos seus ancestrais.

A forma como essa recombinação genética é feita depende do tipo de cruzamento utilizado. Existem diversos tipos de cruzamento, como por exemplo, os descritos a seguir.

Cruzamento de 1-Ponto e N-Pontos

Na reprodução de 1-Ponto é escolhido um ponto de forma aleatória nos dois pais e então, as informações anteriores ao corte no pai_1 são combinadas com as informações posteriores ao corte no pai_2 , resultando assim, em um filho (LACERDA; CARVALHO, 1999). De forma similar, se obtém o segundo filho, conforme Figura 3.1:

Um outro tipo de cruzamento é o de N-Pontos, onde são feitos dois ou mais cortes em cada cromossomo pai e as informações contidas entre os intervalos dos cortes são recombinadas, gerando os dois novos filhos (LACERDA; CARVALHO, 1999). A Figura 3.2 a seguir mostra um exemplo de cruzamento de 2-Pontos.

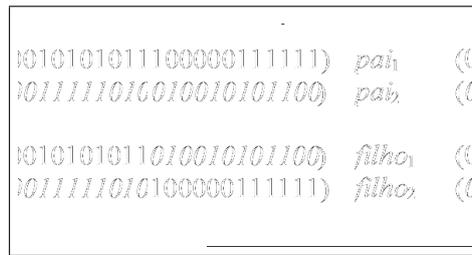


Figura 3.1: Cruzamento de 1-ponto (LACERDA; CARVALHO, 1999).

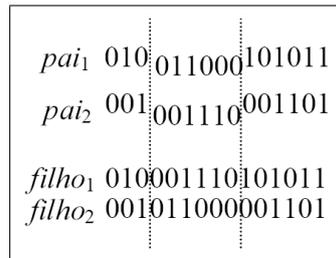


Figura 3.2: Reprodução de 2-pontos (LACERDA; CARVALHO, 1999).

Cruzamento Uniforme

No Cruzamento Uniforme é gerada uma máscara de bits aleatórios. O seu funcionamento acontece da seguinte forma. Se o valor de uma determinada posição da máscara é verdadeiro, essa posição do *pai₁* é copiada para o *filho₁*. No caso de ser verdadeira no *pai₂*, então é a informação do *pai₂* que será copiada para o *filho₁* (LACERDA; CARVALHO, 1999). A geração do segundo filho é dada pelo inverso da explicada anteriormente.

Cruzamento Média

Nesse tipo de cruzamento se tem apenas um filho e este é o resultado da combinação linear dos genes de seus pais. Esse tipo de cruzamento não pode ser aplicado aos indivíduos que são representados de forma binária e simbólica ou inteira.

O cruzamento média foi o operador de cruzamento escolhido para ser utilizado na implementação do presente trabalho.

3.2.2 Mutação

O operador de Mutação é aquele em que se tem a alteração de um ou mais genes do cromossomo, introduzindo aleatoriamente modificações no gene. Esse operador é responsável pela diversificação da população, no sentido de não se ter indivíduos muito parecidos. Porém, ele destrói parte da informação contida no cromossomo (LACERDA; CARVALHO, 1999) (GOLDBERG, 1989) (COELHO, 2003) (LUCAS, 2000).

Na representação binária existem basicamente dois tipos de Mutação, são eles:

- Mutação Clássica: ocorre a troca do valor de um gene no cromossomo por um outro valor gerado randomicamente entre os valores que esse gene pode assumir;

Antes	<i>filho₁</i>	(0010101010010010101100)
	<i>filho₂</i>	(0011111011100000111111)
Depois	<i>filho₁</i>	(0010 <u>0</u> 010100100101 <u>1</u> 1100)
	<i>filho₂</i>	(0011111011 <u>0</u> 00000111111)

Figura 3.3: Mutação Clássica em Representação Binária.

- *Creep*: faz uso de uma distribuição normal ou uniforme com pouca variância. O valor gerado por essa distribuição é adicionado ao valor que o gene possui antes de sofrer a mutação.

3.3 Métodos de Seleção

A seleção é o processo em que são escolhidos os indivíduos que participarão dos operadores genéticos. A seleção geralmente é feita baseada na aptidão dos indivíduos, ou seja, o seu valor na função objetivo.

Existem vários métodos de seleção, onde se destacam a roleta e os baseados em *ranking* ou torneio (COELHO, 2003) (LUCAS, 2000) (SOUZA, 2006) (WHITLEY, 1998).

- Seleção Proporcional ou Roda Roleta

Esse método consiste em colocar todos os indivíduos em uma roleta, onde a posição de cada indivíduo é proporcional à sua aptidão. A roleta é rodada N vezes, sendo que esse N é o número de indivíduos que serão necessários para se realizar os operadores genéticos. Quanto maior a aptidão do indivíduo, mais chances de ele ser escolhido.

- Amostragem Estocástica ou Universal

Neste método, os indivíduos são colocados em um gráfico do tipo pizza dividido em regiões correspondentes ao número de indivíduos da população. Como no método de seleção visto anteriormente, os indivíduos são distribuídos de acordo com a sua aptidão. Sobre esse gráfico, é colocada uma roleta com ponteiros igualmente espaçados. Os indivíduos que possuírem maior aptidão terão mais chances de serem selecionados, sendo que alguns indivíduos podem vir a desaparecer.

- Seleção por *Ranking*

Na seleção por *ranking* os indivíduos são ordenados em ordem crescente de acordo com o valor de aptidão que possuem. A cada indivíduo é atribuído um número inteiro que corresponde a sua posição no *ranking*. Quanto melhor a sua posição no *ranking*, melhor é a sua aptidão em relação aos outros indivíduos, e portanto, maior a sua probabilidade de ser escolhido. O *ranking* pode ser Linear ou Exponencial.

- Seleção por Torneio

Essa seleção não é baseada na competição entre toda a população e sim dentro de um sub-conjunto. O menor número desse sub-conjunto é dois. O seu funcionamento consiste em selecionar qual é o indivíduo mais apto dentro deste sub-conjunto. Por ser considerado um dos métodos de seleção mais eficientes, a seleção por torneio foi utilizada na implementação do algoritmo apresentado neste trabalho.

- Truncamento

Esse método é baseado em um limiar t que pode assumir valores entre 0 e 1. São selecionados os t melhores indivíduos da população, ou seja, se $t = 0,4$, 40% da população de melhores indivíduos será selecionada e o restante será descartado.

3.4 Elitismo

Essa técnica tem por objetivo copiar o melhor indivíduo para a próxima geração, no sentido de preservar a melhor solução encontrada até o momento, já que quando os indivíduos sofrem a ação dos operadores genéticos, algumas informações importantes podem vir a ser perdidas.

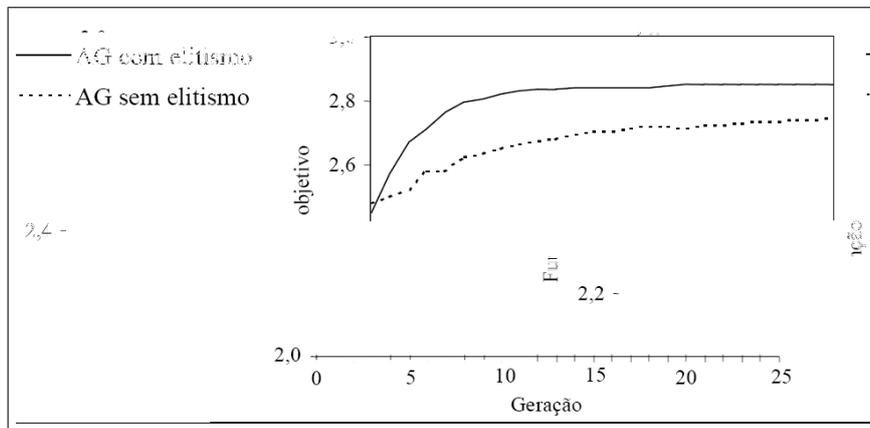


Figura 3.4: Desempenho de um A.G. com e sem Elitismo (LACERDA; CARVALHO, 1999).

3.5 Função de Aptidão

A Função de Aptidão é uma função matemática responsável por medir a qualidade das soluções, ou seja, qualificar se determinado indivíduo representa uma possível solução para o problema que está sendo resolvido.

Dependendo do método de seleção que é utilizado, a Função de Aptidão precisa ser normalizada, já que em métodos como o Roda Roleta por exemplo, não são aceitos valores negativos.

3.6 População Inicial

A geração da população inicial de um Algoritmo Genético consiste em se criar a primeira população de indivíduos em que serão aplicados os passos seguintes do algoritmo.

A forma mais usada de geração da população inicial é uma geração aleatória de indivíduos, e geralmente esse método produz bons resultados. Porém, se uma geração de indivíduos muito pequena for gerada aleatoriamente, é provável que algumas regiões do espaço de busca não venham a ser representadas (WHITLEY, 2001) (SOUZA, 2006).

Uma maneira de se tentar resolver esse problema é gerar uma população mais uniforme, com pontos igualmente espaçados. Outra alternativa é gerar metade da população aleatoriamente e a outra metade restante é obtida através da inversão dos bits da primeira metade (LACERDA; CARVALHO, 1999) (COELHO, 2003).

Existe também uma técnica chamada *seeding* (LACERDA; CARVALHO, 1999), que consiste em utilizar soluções encontradas por outros métodos de otimização. Isso garante que a solução encontrada pelo AG não será pior que as soluções encontradas por estes outros métodos.

3.7 Critérios de Parada

Entende-se por critério de parada o momento em que se deseja interromper a execução do algoritmo.

Existem vários critérios para serem seguidos, e os mais comuns serão apresentados a seguir (GOLDBERG, 1989) (LUCAS, 2000) (LACERDA; CARVALHO, 1999):

- Número de gerações: quando o algoritmo atingir um número máximo de gerações, a execução do algoritmo é interrompida;
- Convergência: quando não ocorre melhora de soluções por um longo número de iterações;
- Valor da Função Objetivo (para problemas de otimização): quando o valor da função objetivo é conhecido, o algoritmo é finalizado quando se encontra esse valor.

O critério de parada utilizado no presente trabalho foi o de número de gerações sem melhoria.

3.8 Parâmetros

Em um algoritmo genético vários parâmetros controlam o processo evolutivo. Esses parâmetros podem ser qualitativos ou quantitativos. A seguir, alguns desses tipos de parâmetros (LACERDA; CARVALHO, 1999):

- Tamanho da população: do tipo quantitativo, diz respeito a quantos indivíduos farão parte da população a cada geração;
- Taxa de Cruzamento: também do tipo quantitativo, é a probabilidade dos indivíduos sofrerem a ação desse operador;
- Taxa de Mutação: é a probabilidade do conteúdo de um indivíduo ser modificado. Esse parâmetro também é dito do tipo quantitativo;
- Tipo de Cruzamento: é um parâmetro qualitativo. Nele se define qual tipo de Reprodução foi utilizada (1-ponto, N-pontos, média);
- Tipo de Seleção: também é um parâmetro qualitativo onde se tem o tipo de seleção utilizado no desenvolvimento do AG.

3.9 Trabalhos Correlatos

Em (SHEBLE; BRITTIG, 1995) é usado um Algoritmo Genético Básico para resolver um problema de Despacho Econômico. O algoritmo utiliza uma função de avaliação modificada. As restrições são eliminadas pela técnica de multiplicadores de Lagrange. Usando um problema de Despacho Econômico como comparação básica, técnicas diferentes realçaram a eficiência e exatidão do programa e explorou-se a predição de mutação, elitismo, aproximação de intervalo e fatores de penalidade. Dois Algoritmos Genéticos originais são também comparados. Os resultados são verificados por uma amostra do problema usando uma técnica clássica de otimização.

No trabalho de (KIM et al., 2002) é apresentado um Algoritmo Genético para problema de Despacho Econômico com Efeito de Ponto de Válvula. O AG proposto melhora as soluções do Despacho Econômico através da combinação de funções de penalidade para tratar as restrições, evolução a parte de indivíduos de elite, atavismo e cruzamento heurístico. Resultados numéricos nos sistemas de testes consistem de

13 unidades de geração de energia que mostram que o algoritmo proposto é capaz de encontrar soluções melhores que os Algoritmos Genéticos convencionais.

Em (DAMOUSIS; BAKIRTZIS; DOKOPOULOS, 2003) se tem um Algoritmo Genético para resolver problemas de Despacho Econômico com restrições na rede de transmissão. O algoritmo foi implementado com codificação real para minimizar o custo do despacho enquanto satisfaz os limites (restrições) de geração de energia das unidades e suas filiais. Um Algoritmo Genético de codificação binária foi usado para efeitos de comparação. O método proposto foi aplicado na rede elétrica *Crete Island* com resultados satisfatórios. Vários testes com funções de custo convexas e não convexas demonstraram que o Algoritmo Genético proposto localiza soluções ótimas, enquanto é mais eficiente que os Algoritmos Genéticos com codificação binária.

Já em (SAMEDI, 2004) foi desenvolvido um Algoritmo Genético Híbrido Co-Evolutivo para resolver problemas de Despacho Ambiental (DA), Despacho Econômico (DE) e o Despacho Econômico/Ambiental (DEA). Nesse trabalho, o operador de mutação foi formulado como uma modificação da direção do gradiente com o intuito de perturbar ou penalizar os indivíduos e evitar assim, a perda da diversidade da população. Um algoritmo para controlar os parâmetros é usado, o que o caracteriza como um algoritmo co-evolutivo. O modelo desenvolvido é capaz de resolver problemas não-lineares com objetivo único (DE e DA), função multi-objetivo (DEA), função objetivo não-contínua (DE considerando o Efeito de Ponto de Válvula), problemas com restrições lineares (limites operacionais e balanço de potência) e problemas com restrições não-lineares (Despacho Econômico com Restrições Ambientais e Despacho Ambiental com Restrições Econômicas).

No trabalho de (SINHA; CHAKRABARTI; CHATTOPADHYAY, 2003) foram testadas técnicas de programação evolutiva para o problema do Despacho Econômico. Os algoritmos implementados foram o de Programação Evolutiva Clássica com mutação de distribuição Gaussiana, o de Programação Evolucionária com a mutação baseada na distribuição de Cauchy, o de Programação Evolutiva que é a média da mutação de distribuição gaussiana e da distribuição de Cauchy e o de Programação Evolutiva que usa ambas as distribuições, a gaussiana e a de Cauchy na mutação. Os resultados foram comparados em vários aspectos como por exemplo tempo de convergência e os resultados para melhor, médio e pior indivíduo de cada implementação. A implementação com maior destaque foi a Programação Evolutiva com mutação de Cauchy e gaussiana.

Algoritmos Culturais

Os Algoritmos Culturais (AC's) são algoritmos evolucionários baseados no processo de evolução cultural da humanidade (REYNOLDS, 1994). Os AC's foram propostos por Robert Reynolds (REYNOLDS, 1999; REYNOLDS, 2001a; REYNOLDS, 2001b; REYNOLDS, 2003) como um complemento à metáfora evolutiva utilizada na Computação Evolutiva, metáfora essa que se concentra nos aspectos genéticos da evolução e na teoria da seleção natural proposta por Darwin. Em contrapartida, os Algoritmos Culturais baseiam-se em teorias sociais e arqueológicas que modelam a evolução cultural dos povos (BECERRA, 2002).

4.1 Inspiração Natural

Acredita-se que a cultura evolui ao longo das gerações. E além disso, a evolução cultural é mais rápida do que a evolução genética. Isso permite uma melhor adaptação ao ambiente do que a possível adaptação pela genética (REYNOLDS; ZANONI, 1992).

Sugere-se que ao longo dos tempos o ser humano evoluiu um conjunto único

de capacidades que permitiu a formação, codificação e transmissão de informações culturais. O conhecimento deve ser codificado de forma a ser acessível a todos os indivíduos de uma sociedade. Uma vez codificado, esse conhecimento é assimilado por cada indivíduo da sociedade sob o prisma das suas experiências anteriores, podendo este indivíduo incorporar ou não novos conhecimentos àqueles presentes na sua sociedade.

As pesquisas a respeito da evolução cultural focam em dois níveis: micro-evolucionário e macro-evolucionário. No nível micro-evolucionário tem-se a modelagem da população em si. Já no nível macro-evolucionário é modelado o conhecimento adquirido pelos indivíduos ao longo das gerações e que codificado e armazenado ajuda a guiar o comportamento dos indivíduos em suas populações. É importante salientar que as informações culturais podem ser transmitidas tanto entre indivíduos de uma população quanto de uma população para outra.

Os algoritmos culturais têm por objetivo acelerar a taxa de convergências de Algoritmos Evolutivos ou melhorar as populações geradas através de um mecanismo dual de herança.

Na seção seguinte será apresentado o funcionamento geral de um Algoritmo Cultural.

4.2 Funcionamento Básico de um Algoritmo Cultural

Os Algoritmos Culturais (AC) possuem um funcionamento básico proposto por Reynolds (REYNOLDS, 1994) onde são descritos dois componentes principais: Espaço Populacional e Espaço de Crenças. É importante salientar que não é preciso que todas as propriedades descritas sejam implementadas, mas elas serão apresentadas para que se mantenha a completude.

A seguir, são detalhados os dois componentes principais de um Algoritmo Cultural:

- **Espaço Populacional:** conjunto de soluções que pode ser modelado utilizando qualquer técnica de Inteligência Computacional que faça uso de uma

população de indivíduos;

- **Espaço de Crença (*Mappa* do grupo)**: local onde ocorre o armazenamento e representação do conhecimento (experiência ou *mappas* individuais) adquirido ao longo do processo evolutivo. É a partir desse conhecimento armazenado que os indivíduos são guiados na direção das melhores regiões do espaço de busca.

Os indivíduos são descritos por um conjunto de características e comportamentos e por um *mappa* que generaliza os conhecimentos e experiências adquiridos por esse indivíduo. Essas características e comportamentos são modificados por operadores genéticos que podem ser influenciados socialmente. Da mesma maneira, os conhecimentos e experiências são unidos e modificados para formar o espaço de crenças. Essas unificações de modificações também são feitas através de operadores especiais.

Os símbolos utilizados para representar os conhecimentos no espaço de crenças podem ser modificados ao longo das gerações. Dessa forma é possível remover ou adicionar novas características e esquecer ou adquirir conhecimentos através das experiências adquiridas pela população.

A cada nova geração de indivíduos é feita uma avaliação e o conhecimento dos melhores indivíduos pode ou não fazer parte do Espaço de Crença. A nova população a ser gerada é influenciada com o conhecimento anteriormente armazenado através de operadores.

Tanto o espaço de crença quanto os indivíduos de uma população podem ser influenciados pelo que se chama de Protocolos de Interação. A comunicação entre os indivíduos de uma geração e o Espaço de Crenças é dada por um protocolo dito Função de Aceitação. Já a interação do Espaço de Crenças com a população de indivíduos é chamado de Função de Influência.

O funcionamento básico dos Algoritmos Culturais é dado pela Figura 4.1 ou pelo pseudo código 2 a seguir:

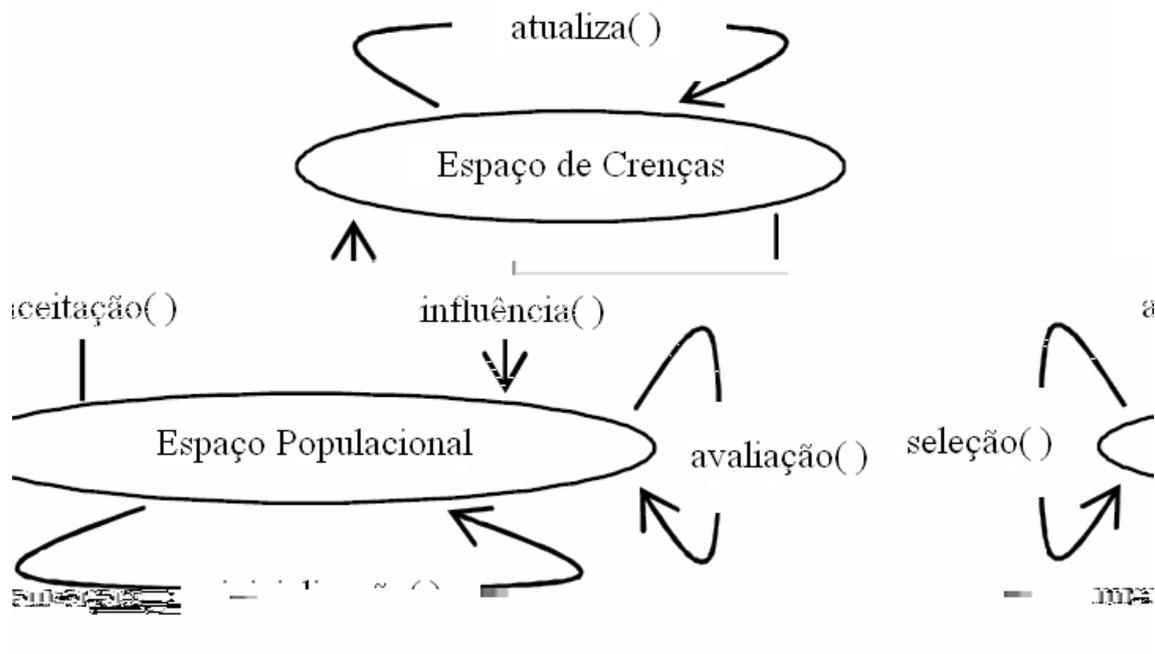


Figura 4.1: Funcionamento Básico de um Algoritmo Cultural.

Algoritmo 2 Algoritmo Cultural (REYNOLDS, 2003)

Algoritmo Cultural

Inicializa a População

Inicializa o Espaço de Crenças

Repita

 Avalie a População

 Ajuste o Espaço de Crenças Através da Função de Aceitação

 Gere a Próxima População a partir da Atual Considerando a Função de Influência

Até que a Condição de Término seja Alcançada

4.3 Principais Características

De acordo com (REYNOLDS, 2003), as principais características demonstradas por um Algoritmo Cultural são:

- Mecanismo Dual de Herança: são herdadas características tanto no nível da população quanto no nível do espaço de crenças;
- Evolução Guiada por Conhecimento: a população é guiada na direção que, segundo o conhecimento armazenado no espaço de crenças, seja a melhor;
- Suporta Hierarquização: tanto a população quanto o espaço de conhecimento podem ser organizados de forma hierárquica, permitindo a criação de nichos e, ao mesmo tempo, uma distribuição do conhecimento adquirido;
- Conhecimento sobre o Domínio Separado dos Indivíduos: o conhecimento adquirido é armazenado no espaço de crenças e compartilhado entre os indivíduos; assim, quando um indivíduo é eliminado da população, o conhecimento adquirido pelo mesmo permanece. Além disso, as técnicas de aquisição e manipulação de conhecimento podem ser adaptadas ao domínio da aplicação sem grandes mudanças na manipulação de indivíduos da população ou do algoritmo evolutivo sendo utilizado. Essa característica permite a criação de ontologias para o domínio sem conhecimentos prévios, ou seja, a criação *on-the-fly* (em tempo de evolução) da ontologia;
- Suporte a Auto-Adaptação em Vários Níveis: permite tanto a auto-adaptação da população quanto do conhecimento e da forma como o conhecimento é adquirido. Ou seja, os parâmetros de controle, a representação, os operadores (tanto genéticos quanto sociais), a avaliação dos indivíduos, e o protocolo de intercomunicação podem ser alterados a qualquer momento da evolução. Isso é particularmente útil para técnicas de meta-evolução (evolução do processo evolutivo);
- Diferentes Taxas de Evolução: a evolução das populações e do conhecimento não precisa ocorrer na mesma taxa. Segundo (REYNOLDS; ZANONI, 1992), o conhecimento é evoluído a uma taxa dez vezes maior que a população;
- Funcionamento: é um modelo computacional que permite a modelagem de diversas formas de evolução cultural. Ou seja, pode evoluir conforme a pesquisa

em sociologia e biologia evoluírem sua visão sobre como a aquisição e compartilhamento do conhecimento (cultura).

O desenvolvimento de um Algoritmo Cultural pode ser dividido em três partes distintas: o desenvolvimento do componente de conhecimento, o desenvolvimento do componente populacional e os protocolos de intercomunicação. Na subseção 4.4.1 será apresentado o desenvolvimento do componente populacional, já o desenvolvimento do componente de conhecimento é mostrado na subseção 4.4.2. Os protocolos de intercomunicação serão apresentados na subseção 4.4.3. Também serão apresentados os Tipos de Conhecimento na subseção 4.4.4.

4.4 Micro Evolução x Macro Evolução

Os Algoritmos Culturais implementam um mecanismo dual de herança. Esse mecanismo permite que os AC explorem tanto a micro evolução quanto a macro evolução. A micro evolução diz respeito à evolução que acontece no nível populacional. Já a macro evolução é a que ocorre sobre a cultura em si, ou seja, a evolução do espaço de crenças. Nos AC a evolução ocorre de forma mais rápida que nas populações sem o mecanismo de macro evolução.

4.4.1 Espaço Populacional

No Espaço Populacional são representadas as características e comportamentos dos indivíduos. Essa representação pode ser feita através de qualquer técnica que faça uso de uma população de indivíduos, como é o caso dos Algoritmos Genéticos, Programação Evolutiva, Programação Genética, Evolução Diferencial, Sistemas Imunes, entre outros (JIN; REYNOLDS, 1999b).

4.4.2 Espaço de Crenças

O Espaço de Crenças é o repositório de símbolos que representam os conhecimentos adquiridos pelo Espaço Populacional ao longo do processo evolutivo. O Espaço de Crenças permite que os indivíduos sejam removidos da população sem

que o conhecimento por eles adquiridos seja perdido, ou seja, se durante o processo de evolução um indivíduo bom é perdido, o seu conhecimento armazenado é propagado para outras gerações. O Espaço de Crenças foi criado para guiar os indivíduos em busca de melhores regiões.

4.4.3 Protocolos de Comunicação

Os Protocolos de Comunicação ditam as regras sobre os indivíduos que podem contribuir com conhecimentos para o Espaço de Crenças (Função de Aceitação) e como o Espaço de Crenças vai influenciar novos indivíduos (Função de Influência).

Função de Aceitação

Na Função de Aceitação são selecionados indivíduos que irão influenciar o Espaço de Crenças atual. A Função de Aceitação pode ser de dois tipos: estática ou dinâmica. Na estática pode se utilizar do

Comumente, é a Função de Influência que determina a direção e o tamanho das modificações impostas aos novos indivíduos.

4.4.4 Tipos de Conhecimento

Existem cinco maneiras de se representar o conhecimento no Espaço de Crenças. A seguir serão descritas cada uma delas:

Conhecimento Situacional

Representa os melhores indivíduos encontrados até determinado momento da evolução. Segundo (IACOBAN; REYNOLDS; BREWSTER, 2003b) ele contém um conjunto de indivíduos da população que servem como exemplo para o resto da população. A quantidade de exemplos pode variar de implementação para implementação, mas costuma ser pequena.

Na Figura 4.2 tem-se um exemplo da estrutura utilizada para representar esse tipo de conhecimento. Cada indivíduo é armazenado junto com a sua aptidão.

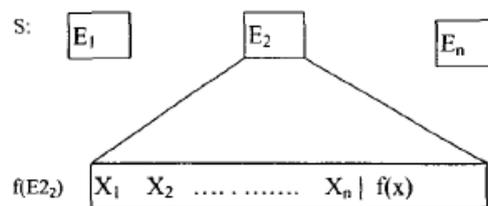


Figura 4.2: Representação de Conhecimento Situacional (IACOBAN; REYNOLDS; BREWSTER, 2003b).

O Conhecimento Situacional é atualizado sempre que é encontrado um indivíduo cuja aptidão supere a aptidão do pior indivíduo armazenado.

Conhecimento Normativo

Representa um conjunto de intervalos que caracterizam os intervalos de valores assumidos pelas características que compõem as melhores soluções. Esses intervalos

servem para guiar os ajustes (mutações) que ocorrem nos indivíduos.

Na Figura 4.3 têm-se a estrutura utilizada por Reynolds e seus alunos, onde são armazenados os valores mínimos e máximos das características dos indivíduos. Junto com esses valores mínimos (l_i) e máximos (u_i) são armazenados as aptidões dos indivíduos que deram origem a cada um desses extremos, L_i e U_i , respectivamente.

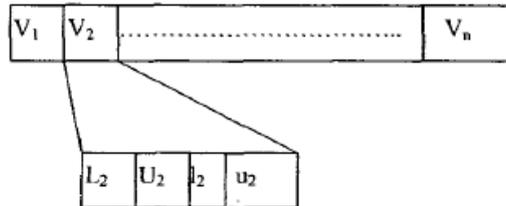


Figura 4.3: Representação de Conhecimento Normativo (IACOBAN; REYNOLDS; BREWSTER, 2003b).

O ajuste do intervalo do Conhecimento Normativo varia de acordo com o melhor indivíduo. Ou seja, se o indivíduo passou pela função de aceitação e seu intervalo é menor que o intervalo armazenado no espaço de crença, o intervalo é reajustado e vice-versa.

Conhecimento do Domínio

Como o próprio nome pressupõe, é específico de cada aplicação. Ele representa conhecimento sobre o domínio do problema para guiar a busca. Esse é o tipo de conhecimento menos utilizado pois é o mais difícil de ser extraído e representado.

Conhecimento Topográfico

Foi proposto com o intuito de extrair padrões de comportamento do espaço de busca. Esse tipo de conhecimento pode espalhar indivíduos sobre todo o espaço de busca. O Conhecimento Topográfico identifica regiões promissoras dentro do espaço de busca e faz com que novos indivíduos as explorem. Ele é o conhecimento que busca explorar diferentes regiões do espaço de busca.

Coello e seus alunos representam esse conhecimento através de uma árvore k - d (Figura 4.4). Segundo (BECERRA; COELLO, 2005) essa representação é mais

eficiente do ponto de vista da memória utilizada para armazená-la.

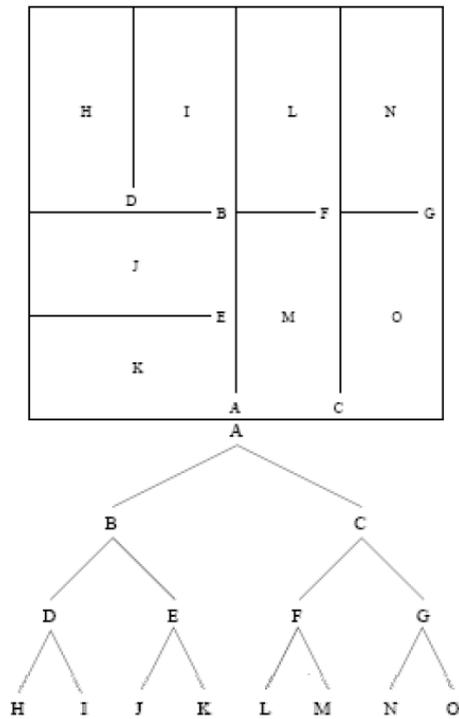


Figura 4.4: Representação de Conhecimento Topográfico (BECERRA; COELLO, 2005).

A atualização do Conhecimento Topográfico é dada quando se encontra um novo indivíduo melhor que o melhor indivíduo da célula. Então, essa célula é dividida em k células menores.

Conhecimento Histórico

Monitora o processo de busca e guarda importantes eventos na busca. Esse conhecimento foi motivado pela necessidade de desenvolver aprendizado em ambientes dinâmicos. Indivíduos guiados pelo conhecimento histórico podem consultar aqueles eventos armazenados para guiar suas decisões quanto a qual direção seguir.

A estrutura utilizada para representar o Conhecimento Histórico é demonstrada na Figura 4.5 em que e_i representa o melhor indivíduo encontrado antes da i -ésima alteração do ambiente. ds_i é a distância média das mudanças para a característica i e dr_i é a direção média se existem mudanças para a característica i .

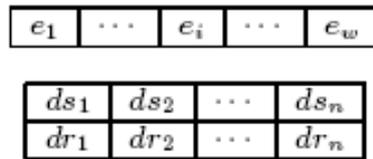


Figura 4.5: Representação de Conhecimento Histórico (BECERRA; COELLO, 2005).

4.5 Trabalhos Correlatos

Em (REYNOLDS; CHUNG, 1997) foi examinado o papel de diferentes formas de conhecimento que podem ser aplicadas no processo de auto-adaptação no nível populacional para funções de otimização (minimização). Uma função de aceitação utilizando sistema de inferência nebuloso foi empregada para selecionar os indivíduos aceitos para a atualização dos conhecimentos no Espaço de Crenças. Para implementar o Espaço Populacional foi utilizada a técnica de Programação Evolutiva. Os resultados mostraram que o *framework* Cultural pode produzir melhorias substanciais de desempenho em termos da qualidade das soluções e do tempo computacional despendido na obtenção das mesmas em problemas de minimização sem restrições.

No trabalho de (STERNBERG; REYNOLDS, 1997) foi inserido um Algoritmo Cultural em um Sistema Especialista de detecção de fraudes. A re-engenharia desse tipo de sistema, que é dinâmico, torna-se muito complexa. Por isso é que se aplicou um Algoritmo Cultural, pois ele provê capacidade de auto-adaptação a sistemas dinâmicos. Para representar um ambiente de desempenho dinâmico, foram usados quatro objetivos de aplicação diferentes. Os objetivos foram caracterização de reivindicações fraudulentas, reivindicações não fraudulentas, reivindicações não fraudulentas ditas anteriormente como fraudulentas e reivindicações fraudulentas ditas anteriormente como não fraudulentas. Os resultados indicam que o Sistema Especialista Aculturado pode produzir informações necessárias para responder a ambientes de desenvolvimento dinâmico. É possível também implementar uma comunicação direta entre o Algoritmo Cultural e o Sistema Especialista e fornecer uma resposta automatizada para mudanças ambientais.

Já em (JIN; REYNOLDS, 1999a) foi definida uma região n-dimensional, chamada célula de crença, que pode fornecer um mecanismo explícito capaz de suportar aquisição, armazenamento e integração de conhecimento sobre as restrições. No

Algoritmo Cultural, o espaço de crença pode conter um conjunto de esquemas, cada um deles pode ser usado para guiar a busca da evolução da população. Esse tipo de região baseada em esquemas pode ser usada para guiar a busca otimizada para punir as regiões ineficazes e promover as regiões promissoras. Esse modelo foi comparado com quatro configurações de Algoritmos Culturais que manipulam os mesmos esquemas de problemas.

No trabalho de (PENG; REYNOLDS; BREWSTER, 2003) tem-se um Algoritmo Cultural que foi configurado usando cinco tipos de conhecimentos no espaço de crença e um modelo de Programação Evolutiva no espaço populacional. Notou-se que os cinco tipos de conhecimento tiveram um comportamento social em nível de meta-espaço enquanto resolveu o problema. Foi investigado se esse comportamento social no meta espaço induzia socialmente a população. Os resultados mostram que cada fonte de conhecimento pode controlar o tamanho de interação dos indivíduos no espaço populacional.

Metodologia Proposta

O objetivo desse trabalho é o desenvolvimento de um Algoritmo Cultural com espaço populacional baseado em Algoritmos Genéticos para resolver problemas de Despacho Econômico, Despacho Ambiental e Despacho Econômico/Ambiental.

O desenvolvimento desse algoritmo tem o propósito de responder às seguintes questões:

- Qual a influência dos tipos de conhecimento (situacional, normativo, situacional/normativo) utilizados no Algoritmo Cultural?
- Qual a influência dos tipos de operadores (mutação e cruzamento)?
- Qual a sensibilidade do algoritmo em relação aos seus parâmetros iniciais?
- Os resultados obtidos pelo algoritmo proposto são compatíveis com os resultados encontrados por outros algoritmos na literatura?

As respostas para essas questões são relevantes não somente para aferir a capacidade de um Algoritmo Cultural em resolver o problema em questão (Despacho),

mas também servem para estimar a capacidade do algoritmo em resolver problemas correlatos como o problema de *Unit Commitment*.

O desenvolvimento do algoritmo levou em consideração aspectos como portabilidade, facilidade de modificações/melhorias futuras e desempenho. Por isso, ele foi codificado na linguagem Java versão 5.0 no ambiente de desenvolvimento NetBeans 5.5.

5.1 Modelo Computacional Desenvolvido

O Algoritmo Cultural desenvolvido nesse trabalho segue os passos apresentados pelo Algoritmo 3. Em seguida, a seqüência seguida por esse algoritmo pode ser facilmente compreendida pelo Diagrama Esquemático mostrado na Figura 5.1.

Algoritmo 3 Algoritmo Cultural Implementado

Algoritmo Cultural

Criar Espaço de Crença;

Inicializar a População;

Avaliar a População Inicial;

Enquanto (!Condição de Parada()) **faça**

 Selecionar País;

 Gerar novos Indivíduos pelas Funções de Influência;

 Avaliar os novos Indivíduos;

 Selecionar Indivíduos para a Próxima Geração;

 Atualizar Espaço de Crenças;

 Atualizar Parâmetros;

Fim Enquanto

Os passos do algoritmo serão explicados nas subseções seguintes.

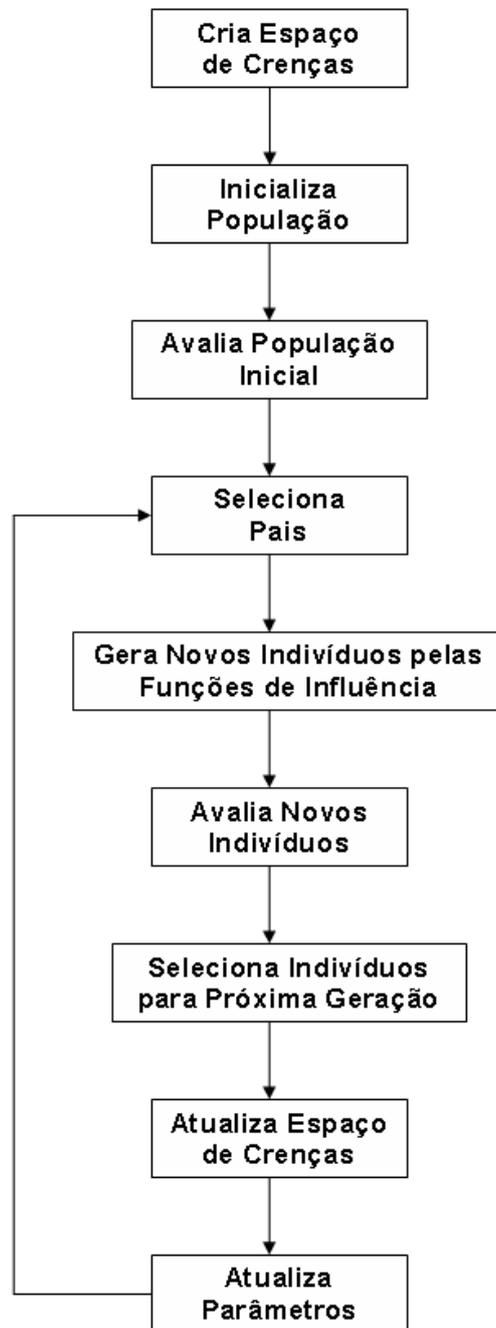


Figura 5.1: Diagrama Esquemático dos passos do Algoritmo Cultural Desenvolvido.

5.1.1 Criação do Espaço de Crenças, Inicialização e Avaliação da População

O primeiro passo na execução é criar o espaço de crenças. Essa criação envolve a inicialização dos vários tipos de conhecimento e das probabilidades de utilização dos mesmos.

O segundo passo é inicializar a população de indivíduos que passará pelo processo de evolução. Nesse trabalho os indivíduos são compostos por vetores que armazenam os valores de potência de cada gerador, com codificação real. A população é inicializada de maneira aleatória de acordo com a Equação 5.1:

$$ind_{i,j} = lim_inf_j + (RANDOM() * (lim_sup_j - lim_inf_j)) \quad \forall i, j$$

Essa equação é a mesma utilizada em (SAMÉD, 2004) para o problema do despacho econômico/ambiental.

Após isso o algoritmo entra no seu *loop* principal que é executado até que a condição de parada seja alcançada.

5.1.2 Seleção dos Pais

Os pais que serão utilizados na geração dos filhos são selecionados. Essa seleção é realizada através de um torneio. Nesse torneio um indivíduo A é melhor do que um indivíduo B se uma das seguintes condições é atendida:

- Se nenhum dos indivíduos viola a restrição de demanda mínima (ver Equação 5.3) e o indivíduo A possui melhor valor de aptidão do que o indivíduo B;
- Se o indivíduo A não viola a restrição de demanda e o indivíduo B viola essa restrição;
- Se ambos os indivíduos violam a restrição de demanda mínima e o valor de violação do indivíduo A é menor do que o valor de violação do indivíduo B.

Ou seja, o torneio favorece indivíduos factíveis com bom valor de aptidão e indivíduos infactíveis que violam pouco a restrição de demanda mínima que é dada pela Equação 5.3,

$$\begin{aligned} violacao &= P_D - \sum_{j=1}^n ind_{i,j}, & \text{se } \sum_{j=1}^n ind_{i,j} < VD \\ violacao &= 0, & \text{caso contrário} \end{aligned} \quad (5.3)$$

em que *violacao* é o valor que falta para completar a demanda mínima do sistema, V_D é o valor da demanda mínima e $ind_{i,j}$ é o valor da potência do j-ésimo gerador do i-ésimo indivíduo.

5.1.3 Geração e Seleção de Indivíduos e Atualização do Espaço de Crenças

Os filhos são gerados através da aplicação das funções de influência (ver mais detalhes na Seção 5.3) e avaliados da mesma maneira que os indivíduos da população inicial. As funções de influência são modificações dos operadores de mutação e cruzamento para utilizar o conhecimento armazenado ao longo da evolução no espaço de crenças.

Os melhores indivíduos gerados são então selecionados para compor a população da próxima geração (eles são ordenados da mesma maneira que ocorre no torneio). Novos conhecimentos são extraídos da população e utilizados na atualização do espaço de crenças.

Finalmente, o *loop* principal é concluído com alguns cálculos que servem para atualizar os principais parâmetros do algoritmo (ver Seção 5.5), os quais serão utilizados na próxima iteração do *loop* principal.

A seguir serão detalhados os principais componentes do algoritmo.

5.2 Espaço Populacional

O Espaço Populacional de um Algoritmo Cultural é o componente responsável pela micro evolução do algoritmo e geralmente corresponde a algum algoritmo de Computação Evolutiva. Neste trabalho o Espaço Populacional é implementado na forma de um Algoritmo Genético.

Como em todo Algoritmo Genético, o Espaço Populacional deste trabalho possui uma população de cromossomos (chamados de indivíduos nesse trabalho por causa da terminologia dos Algoritmos Culturais), operadores genéticos, um método de seleção dos pais e um método de seleção dos indivíduos da próxima população (política de substituição na terminologia dos Algoritmos Genéticos).

Os operadores genéticos utilizados neste trabalho são variações do cruzamento aritmético e da mutação gaussiana e serão melhor detalhados juntamente com os tipos de conhecimento.

Como dito anteriormente, a seleção dos pais ocorre através de um torneio. Durante esse torneio são escolhidos aleatoriamente n indivíduos da população e o melhor deles é selecionado. Esse torneio é repetido até que um número m de pais seja selecionado. A pressão seletiva do método depende do valor de n : quanto maior o valor, maior a pressão seletiva.

A seleção dos indivíduos da próxima geração é feita pelo método de substituição geracional. Na implementação particular utilizada nesse trabalho apenas os filhos competem por vagas na próxima população. Isso torna o algoritmo não elitista.

5.3 Espaço de Crença

O Espaço de Crenças é o componente responsável pela macro evolução do Algoritmo Cultural. A sua função é a de armazenar as experiências extraídas dos indivíduos nos conhecimentos.

Neste trabalho foram utilizados três tipos de conhecimentos: o Conhecimento Situacional, Conhecimento Normativo e o Conhecimento Situacional/Normativo. A forma como eles foram desenvolvidos será melhor detalhada nas Subseções 5.4.1, 5.4.2 e 5.4.3.

Como descrito no Capítulo 4, uma característica importante do Espaço de Crenças é a forma como seus Protocolos de Comunicação (Função de Aceitação e Funções de Influência) são implementados. A Função de Aceitação utilizada é a Função de Aceitação Dinâmica, onde a quantidade de indivíduos aceitos varia de geração para geração. A Função de Influência Principal é utilizada para escolher qual dos tipos de conhecimento será utilizado para influenciar a geração dos indivíduos. Nesse trabalho, a Função de Influência Principal adapta geração a geração as probabilidades de cada tipo de conhecimento de acordo com o sucesso que eles tiveram na última geração. As demais funções de influência serão detalhadas a seguir juntamente com os respectivos tipos de conhecimentos.

5.4 Tipos de Conhecimento

Os tipos de conhecimento compõem o Espaço de Crenças e, por conseguinte, do Algoritmo Cultural e merecem atenção especial. Como dito anteriormente foram implementados os conhecimentos Situacional, Normativo e Situacional/Normativo. Esses tipos de conhecimentos foram escolhidos por serem os que mais influenciam a evolução do Espaço Populacional (IACOBAN; REYNOLDS; BREWSTER, 2003b) (IACOBAN; REYNOLDS; BREWSTER, 2003a) (REYNOLDS; PENG; BREWSTER, 2003).

Cada conhecimento tem diferentes influências nos operadores do Espaço Populacional. No caso particular do algoritmo proposto cada conhecimento interfere tanto no operador de mutação quanto no operador de cruzamento. Um detalhe importante das funções de influência é que elas garantem que os indivíduos gerados atendem às restrições de valores operacionais mínimos e máximos admitidos para cada gerador. Dessa forma pode-se dizer que, de acordo com a restrição de limites operacionais de cada um dos geradores, não existem indivíduos inactiváveis. Isso é garantido pela seguinte equação:

$$\begin{aligned}
 ind_{i,j} &= \lim_inf_j, & \text{se } ind_{i,j} < \lim_inf_j \\
 ind_{i,j} &= \lim_sup_j, & \text{se } ind_{i,j} > \lim_sup_j \\
 ind_{i,j} &= ind_{i,j}, & \text{caso contrário}
 \end{aligned} \tag{5.4}$$

em que $ind_{i,j}$ é o j -ésimo gene do i -ésimo indivíduo, $\lim_inf_{i,j}$ é o limite mínimo de potência para o j -ésimo gerador e $\lim_sup_{i,j}$ é o limite máximo de potência para o j -ésimo gerador.

Ou seja, se o valor de potência de um gerador é menor do que o limite mínimo, após uma função de influência, ele é setado como sendo o valor mínimo, de maneira análoga, se ele é maior que o limite superior ele é setado como sendo o valor máximo, caso contrário o valor é um valor válido e não é modificado.

Essa verificação é feita sempre que um determinado número de indivíduos é aceito para contribuir com o seu conhecimento no Espaço de Crenças.

Nas Subseções 5.4.1, 5.4.2 e 5.4.3 será mostrado como foram desenvolvidos os conhecimentos.

Função de Influência do Conhecimento Situacional na Mutação

O Conhecimento Situacional influencia a mutação da seguinte forma: ao invés de aplicar a mutação num gene do indivíduo sofrendo a mutação, ele aplica a mutação num gene de um dos melhores indivíduos e coloca esse valor no indivíduo sendo mutado. Em termos matemáticos temos:

$$ind_{i,j} = melhor_{k,j} + mult * perc_g * (lim_sup_j - lim_inf_j) \quad (5.5)$$

em que $ind_{i,j}$ é o j -ésimo gene (gerador) do indivíduo sendo mutado, $melhor_{k,j}$ é o j -ésimo gene de um dos melhores indivíduos armazenado no Conhecimento Situacional, $mult$ é um fator multiplicativo adaptado ao longo das gerações, $perc_g$ é um valor aleatório gerado de acordo com uma distribuição gaussiana de média zero e desvio padrão um (implementado de acordo com (KNUTH, 1998)), lim_sup_j é o limite superior para o j -ésimo gene e lim_inf_j é o limite inferior para o j -ésimo gene.

Isso faz com que o j -ésimo gene do indivíduo sendo mutado se assemelhe ao j -ésimo gene de um dos melhores indivíduos. O fator $mult$ é maior no começo da evolução e vai decaindo ao longo das gerações. O propósito disso é fazer uma maior exploração no início e um ajuste fino no final do processo, ou seja, no início o multiplicador é grande e faz com que a mutação possa dar grandes saltos no espaço de busca. Ao longo do processo evolutivo esse fator é decrescido, tornando a mutação cada vez mais suave. No final do processo esse valor é bastante baixo e faz com a mutação efetue apenas um ajuste fino dos valores. O fator $perc$ é dado por uma gaussiana de média zero e desvio padrão um, fazendo com que o valor mutado tenha uma grande probabilidade de ser próximo ao valor existente e uma pequena probabilidade de ser muito distante. Além disso, a gaussiana permite que ocorram tanto acréscimos quanto decréscimos no valor. O fator $lim_sup_j - lim_inf_j$ faz com que o intervalo de mutação seja proporcional ao tamanho do intervalo entre a potência mínima e máxima permitida para o j -ésimo gerador. A lógica disso é fazer com que genes com intervalos pequenos sejam explorados mais suavemente enquanto genes com grandes intervalos sejam bem explorados.

Um detalhe importante da mutação é que ela somente é aplicada a um dos genes do indivíduo, isso visa evitar perturbar demais os indivíduos, permitindo uma

exploração mais suave do espaço de busca.

Função de Influência do Conhecimento Situacional no Cruzamento

No cruzamento influenciado pelo Conhecimento Situacional um dos pais utilizados na geração dos filhos é escolhido pelo processo de seleção descrito na Seção 5.2 e o outro pai é um dos melhores indivíduos armazenados no conhecimento.

O cruzamento foi implementado como uma combinação linear dos dois indivíduos e gera dois filhos (cada filho é gerado com um percentual complementar ao utilizado na geração do outro). A combinação linear permite que os filhos gerados estejam a uma distância intermediária dos dois pais, ou seja, permite explorar a região do espaço de busca entre os pais. Como um dos pais é um dos melhores indivíduos encontrados ao longo da evolução, esse operador ajuda a explorar bem as regiões do espaço de busca ao redor dos melhores indivíduos.

A Equação 5.6 explica matematicamente o processo.

$$\begin{aligned} \text{filho}_{1,j} &= (\text{perc}_u * \text{pai}_{1,j}) + ((1 - \text{perc}_u) * \text{melhor}_{k,j}), \quad \forall j \\ \text{filho}_{2,j} &= ((1 - \text{perc}_u) * \text{pai}_{1,j}) + (\text{perc}_u * \text{melhor}_{k,j}), \quad \forall j \end{aligned} \quad (5.6)$$

em que $\text{filho}_{i,j}$ é o j -ésimo gene de um dos filhos sendo gerados, perc_u é um valor aleatório gerado de acordo com uma distribuição uniforme no intervalo entre zero e um, $\text{pai}_{1,j}$ é o j -ésimo gene do pai selecionado por torneio da população, $\text{melhor}_{k,j}$ é o j -ésimo gene de um dos melhores indivíduos armazenados no Conhecimento Situacional.

5.4.2 Conhecimento Normativo

O Conhecimento Normativo armazena os intervalos de valores de cada gene (gerador) onde os bons indivíduos se concentram. O objetivo do Conhecimento Normativo é manter os valores dos genes dos indivíduos da população dentro ou o mais próximo possível desses intervalos.

Os intervalos são armazenados em vetores de registros de quatro posições: o valor mínimo e máximo do intervalo e suas aptidões correspondentes. A atualização do Conhecimento Normativo ocorre segundo o Algoritmo 5.

Algoritmo 5 Atualização do Conhecimento Normativo

Para cada gerador j
 Encontre min_j e apt_min_j
Se $min_j < normativo_inf_j$
 $normativo_inf_j = min_j$;
 $apt_normativo_inf_j = apt_min_j$;
Senão Se $apt_min_j > apt_normativo_inf_j$
 $normativo_inf_j = min_j$;
 $apt_normativo_inf_j = apt_min_j$;
Fim Se
 Encontre max_j e apt_max_j
Se $max_j > normativo_sup_j$
 $normativo_sup_j = max_j$;
 $apt_normativo_sup_j = apt_max_j$;
Senão Se $apt_max_j > apt_normativo_sup_j$
 $normativo_sup_j = max_j$;
 $apt_normativo_sup_j = apt_max_j$;
Fim Se
Fim Para

em que min_j é o valor mínimo de potência encontrado para o j -ésimo gerador dentre os indivíduos aceitos pela Função de Aceitação, apt_min_j é a aptidão do indivíduo que possui o valor min_j , $normativo_inf_j$ é o limite inferior do intervalo normativo para o j -ésimo gerador, $apt_normativo_inf_j$ é o valor de aptidão do indivíduo que possui o valor $normativo_inf_j$, max_j é o valor máximo de potência encontrado para o j -ésimo gerador dentre os indivíduos aceitos pela Função de Aceitação, apt_max_j é a aptidão do indivíduo que possui o valor max_j , $normativo_sup_j$ é o limite superior do intervalo normativo para o j -ésimo gerador e $apt_normativo_sup_j$ é o valor de aptidão do indivíduo que possui o valor $normativo_sup_j$.

A lógica utilizada na atualização é a seguinte: se um valor (min_j ou max_j) provocar uma expansão do intervalo normativo esse valor é aceito independentemente da sua aptidão, em contrapartida, se ele provocar uma contração ele somente é aceito se sua aptidão for melhor do que a aptidão que está associada ao limite que deve ser modificado. Ou seja, a atualização favorece expansões enquanto é bastante restritiva quanto a contrações.

A forma como esse tipo de conhecimento influencia os indivíduos do espaço populacional é mostrada na seqüência.

Função de Influência do Conhecimento Normativo na Mutação

A mutação dos indivíduos da população é influenciada pelo Conhecimento Normativo da seguinte forma: sorteia-se uma posição a ser mutada, se o valor de potência dessa posição for inferior ao limite inferior contido no intervalo normativo ele deve ser incrementado na tentativa de colocar o valor dentro do intervalo, se o valor for superior ao limite superior do intervalo ele deve ser decrementado na tentativa de jogá-lo para dentro do intervalo, caso contrário o valor já está dentro do intervalo normativo e pode tanto ser acrescido quanto decrescido, preferencialmente de um valor pequeno.

A Equação 5.7 descreve matematicamente o processo.

$$\begin{aligned}
 ind_{i,j} &= ind_{i,j} + (perc_u * (norm_sup_j - norm_inf_j)), & \text{se } ind_{i,j} < norm_inf_j \\
 ind_{i,j} &= ind_{i,j} - (perc_u * (norm_sup_j - norm_inf_j)), & \text{se } ind_{i,j} > norm_sup_j \\
 ind_{i,j} &= ind_{i,j} + (perc_g * (norm_sup_j - norm_inf_j)), & \text{caso contrário}
 \end{aligned} \tag{5.7}$$

em que $ind_{i,j}$ é o j -ésimo gene do indivíduo sendo mutado, $perc_u$ é um valor aleatório gerado de acordo com uma distribuição uniforme no intervalo entre zero e um, $norm_inf_j$ e $norm_sup_j$ são os valores dos limites inferior e superior do intervalo normativo, respectivamente, e $perc_g$ é um valor gerado de acordo com uma distribuição gaussiana de média zero e desvio padrão um.

O termo $norm_sup_j - norm_inf_j$ faz com que a mutação seja proporcional ao tamanho do intervalo normativo para o j -ésimo gerador. Isso faz com que a mutação tenda a ser maior no início da evolução (visto que o intervalo ainda não está afinado) e menor no final da evolução (porque nesse ponto o Conhecimento Normativo já absorveu conhecimento suficiente para restringir bastante o tamanho do intervalo).

Função de Influência do Conhecimento Normativo no Cruzamento

Na reprodução influenciada pelo Conhecimento Normativo os pais utilizados na geração dos filhos são escolhidos pelo processo de seleção por torneio descrito anteriormente.

Da mesma forma como foi feito na influência do Conhecimento Situacional, o cruzamento foi implementado como uma combinação linear dos dois indivíduos selecionados. O diferencial dessa função de influência é que ela faz uma verificação de onde se encontram os valores dos genes dos indivíduos selecionados em relação aos limites inferiores e superiores do intervalo do Conhecimento Normativo. Se o valor do gene de um dos pais está abaixo do limite inferior do intervalo, seu filho é gerado pela adição de um percentual do valor do mesmo gene no outro pai, se o valor do seu gene está acima do limite superior do intervalo normativo para esse gene ele é decrementado de uma quantidade proporcional ao valor para esse gene no outro pai, caso contrário o valor está dentro do intervalo e é gerado pela combinação linear entre os valores dos genes dos pais. Esse processo faz com que os filhos tendam a ter valores dentro ou próximos do intervalo normativo.

Formalmente tem-se a Equação 5.8:

$$\begin{aligned}
 & \textit{filho}_{1,j} = \textit{pai}_{1,j} + \textit{perc}_u * \textit{pai}_{2,j}, & \text{se } \textit{pai}_{1,j} < \textit{norm_inf}_j \\
 & \textit{filho}_{1,j} = \textit{pai}_{1,j} - \textit{perc}_u * \textit{pai}_{2,j}, & \text{se } \textit{pai}_{1,j} > \textit{norm_sup}_j \\
 & \textit{filho}_{1,j} = (\textit{perc}_u * \textit{pai}_{1,j}) + ((1 - \textit{perc}_u) * \textit{pai}_{2,j}), & \text{caso contrário} \\
 & e & \\
 & \textit{filho}_{2,j} = \textit{pai}_{2,j} + \textit{perc}_u * \textit{pai}_{1,j}, & \text{se } \textit{pai}_{2,j} < \textit{norm_inf}_j \\
 & \textit{filho}_{2,j} = \textit{pai}_{2,j} - \textit{perc}_u * \textit{pai}_{1,j}, & \text{se } \textit{pai}_{2,j} > \textit{norm_sup}_j \\
 & \textit{filho}_{2,j} = (\textit{perc}_u * \textit{pai}_{2,j}) + ((1 - \textit{perc}_u) * \textit{pai}_{1,j}), & \text{caso contrário}
 \end{aligned} \tag{5.8}$$

em que $\textit{filho}_{i,j}$ é o j -ésimo gene de um dos filhos gerado através do cruzamento, $\textit{pai}_{i,j}$ é o j -ésimo gene de um dos pais selecionados, \textit{perc}_u é um valor aleatório gerado de acordo com uma distribuição uniforme no intervalo entre zero e um e $\textit{norm_inf}_j$ e $\textit{norm_sup}_j$ são, respectivamente, os limites inferior e superior do intervalo normativo.

5.4.3 Conhecimento Situacional/Normativo

O Conhecimento Situacional/Normativo, como o próprio nome já sugere, agrega conceitos dos Conhecimentos Situacional e Normativo. Esse conhecimento não possui um método de atualização, pois tanto os melhores indivíduos quanto o intervalo normativo são obtidos, respectivamente, dos conhecimentos Situacional e Normativo.

A escolha dos indivíduos que participarão dos operadores segue as características de escolha do Conhecimento Situacional. Já a forma como esses indivíduos serão influenciados pela mutação e cruzamento é regida pelas regras aplicadas no Conhecimento Normativo, ou seja, dependem do intervalo normativo.

A seguir serão descritos como os operadores são influenciados por esse conhecimento.

Função de Influência do Conhecimento Situacional/Normativo na Mutação

Nessa mutação são inicialmente sorteados dois valores: a posição a ser mutada (j) e qual melhor indivíduo armazenado no Conhecimento Situacional será utilizado (k). Após isso a mutação ocorre de maneira semelhante à mutação influenciada pelo Conhecimento Normativo, mas com a diferença que o intervalo e a mutação são baseados no valor do j -ésimo gene do k -ésimo melhor indivíduo.

A Equação 5.9 mostra matematicamente como é realizada a mutação.

$$\begin{aligned}
 ind_{i,j} &= melhor_{k,j} + (perc * (norm_sup_j - norm_inf_j)), & \text{se } melhor_{k,j} < norm_inf_j \\
 ind_{i,j} &= melhor_{k,j} - (perc * (norm_sup_j - norm_inf_j)), & \text{se } melhor_{k,j} > norm_sup_j \\
 ind_{i,j} &= melhor_{k,j} + (perc2 * (norm_sup_j - norm_inf_j)), & \text{caso contrário}
 \end{aligned}
 \tag{5.9}$$

em que $ind_{i,j}$ é o j -ésimo gene do indivíduo sendo mutado, $melhor_{k,j}$ é o j -ésimo gene do k -ésimo melhor indivíduo, $perc$ é um valor aleatório gerado de acordo com uma distribuição uniforme no intervalo entre zero e um, $norm_inf_j$ e $norm_sup_j$ são

os valores dos limites inferior e superior do intervalo normativo, respectivamente, e $perc_2$ é um valor gerado de acordo com uma distribuição gaussiana de média zero e desvio padrão um.

Novamente, o termo $norm_sup_j - norm_inf_j$ faz com que a mutação seja proporcional ao tamanho do intervalo normativo para o j -ésimo gerador.

A lógica dessa mutação é fazer com que o gene sendo modificado seja semelhante ao mesmo gene de um dos melhores indivíduos e ao mesmo tempo esteja dentro ou próximo do intervalo normativo.

Função de Influência do Conhecimento Situacional/Normativo no Cruzamento

A influência desse conhecimento no cruzamento é feita da mesma forma que no Conhecimento Normativo com a exceção de que um dos pais é um dos melhores indivíduos armazenados no Conhecimento Situacional e o outro é um indivíduo selecionado da população por torneio.

A Equação 5.10 descreve matematicamente o que ocorre durante a reprodução.

$$\begin{aligned}
 filho_{1,j} &= pai_{1,j} + perc * melhor_{k,j}, & \text{se } pai_{1,j} < norm_inf_j \\
 filho_{1,j} &= pai_{1,j} - perc * melhor_{k,j}, & \text{se } pai_{1,j} > norm_sup_j \\
 filho_{1,j} &= (perc * pai_{1,j}) + ((1 - perc) * melhor_{k,j}), & \text{caso contrário} \\
 e \\
 filho_{2,j} &= melhor_{k,j} + perc * pai_{1,j}, & \text{se } melhor_{k,j} < norm_inf_j \\
 filho_{2,j} &= melhor_{k,j} - perc * pai_{1,j}, & \text{se } melhor_{k,j} > norm_sup_j \\
 filho_{2,j} &= (perc * melhor_{k,j}) + ((1 - perc) * pai_{1,j}), & \text{caso contrário}
 \end{aligned} \tag{5.10}$$

em que $filho_{i,j}$ é o j -ésimo gene de um dos filhos gerado através da reprodução, $pai_{1,j}$ é o j -ésimo gene de um do pai selecionado por torneio, $melhor_{k,j}$ é o j -ésimo gene do k -ésimo melhor indivíduo, $perc$ é um valor aleatório gerado de acordo com uma distribuição uniforme no intervalo entre zero e um e $norm_inf_j$ e $norm_sup_j$ são, respectivamente, os limites inferior e superior do intervalo normativo.

A influência desse conhecimento visa fazer com que os indivíduos sendo gerados sejam semelhantes a um dos melhores indivíduos e ao mesmo tempo estejam dentro ou próximos dos valores do intervalo normativo.

5.5 Adaptação dos Parâmetros

O ajuste de parâmetros de Algoritmos Evolutivos é uma tarefa complexa e bastante controversa, visto que é muito difícil provar que um determinado conjunto de parâmetros é ótimo para um determinado problema.

O controle automático de parâmetros surge como uma alternativa elegante e eficiente para esse problema. Segundo (EIBEN; HINTERDING; MICHALEWICZ, 1999) e (HINTERDING; MICHALEWICZ; EIBEN, 1997) o controle automático de parâmetros pode ser classificado de acordo com o tipo e nível de adaptação.

No tocante ao tipo de adaptação tem-se (HINTERDING; MICHALEWICZ; EIBEN, 1997; EIBEN; HINTERDING; MICHALEWICZ, 1999):

- Determinístico: ocorre quando um parâmetro é modificado de maneira determinística, seguindo regras;
- Adaptativo: ocorre quando um parâmetro é modificado com o auxílio de informações extraídas do processo evolutivo;
- Auto-Adaptativo: ocorre quando um parâmetro é modificado como parte do processo evolutivo, ou seja, quando o parâmetro é alterado por uma mutação, cruzamento, ou equivalente. Esse tipo de controle de parâmetros também é denominado Co-Evolução.

Quanto ao nível de adaptação tem-se (HINTERDING; MICHALEWICZ; EIBEN, 1997):

- Ambiental: é realizada quando o ambiente ao redor dos indivíduos é modificado;
- Populacional: acontece quando a modificação no parâmetro afeta toda a população;

- Individual: ocorre quando um parâmetro é ajustado para um indivíduo em particular;
- De gene: quando a modificação afeta apenas um gene de um indivíduo.

Nesse trabalho existem vários pontos de controle automático: a Função de Aceitação, a taxa de mutação, a taxa de reprodução, probabilidade da influência ser exercida pelos conhecimentos Situacional, Normativo e Situacional/Normativo, o passo (tamanho) da mutação sob influência dos conhecimentos Normativo e Situacional/Normativo e o intervalo normativo.

A taxa de aceitação é o parâmetro que diz quantos indivíduos serão aceitos para contribuir com o seu conhecimento no Espaço de crenças. O controle desse parâmetro pode ser classificado como determinístico e populacional. Ele é feito pela Equação 5.11.

$$aceitos = taxa_aceitos + (taxa_aceitos/geracao) \quad (5.11)$$

em que *aceitos* é o percentual de indivíduos a serem aceitos para atualização do espaço de crenças, *taxa_aceitos* é um parâmetro de entrada que determina o percentual mínimo de indivíduos aceitos e *geracao* é o número da geração corrente. Essa função aceita muitos indivíduos no início da evolução e, progressivamente, aceita menos indivíduos conforme o processo evolui.

O controle da taxa de cruzamento e mutação estão correlacionados, visto que na implementação do presente trabalho eles foram feitos sendo um o complemento do outro. Ambos são do tipo adaptativo e populacional. A atualização dessas taxas são dadas pelas Equações 5.12 e 5.13.

$$taxaMutacao = 0.1 + 0.8 * (0.9 * taxaMutacao + 0.1 * sucessoMutacao / sucessoOperadores) \quad (5.12)$$

$$taxaCruzamento = 0.1 + 0.8 * (0.9 * taxaCruzamento + 0.1 * sucessoCruzamento / sucessoOperadores) \quad (5.13)$$

5.5 *Adaptação dos Parâmetros*

nhcimentos Situacional, Normativo e Situacional/Normativo, ou seja, essas variáveis são incrementadas de 1 (um) sempre que esses conhecimentos são aplicados aos indivíduos e esses indivíduos são selecionados para fazer parte da população e *sucessoConhecimentos* é a soma dos valores das variáveis *sucessoSituacional*, *sucessoNormativo* e *sucessoSituacionalNormativo*.

Assim como ocorre com as taxas de mutação e cruzamento, essas equações garantem que a probabilidade mínima de qualquer tipo de conhecimento é de 10%. Mas diferentemente das taxas de mutação e cruzamento, as probabilidade dos conhecimentos dependem única e exclusivamente do seu desempenho na última geração. Isso se deve ao fato de os conhecimentos serem constantemente adaptados ao longo do processo evolutivo, fazendo com que os seus efeitos sejam alterados rapidamente, o que exige uma fórmula que permita mudanças rápidas nas probabilidades.

Os tipos de conhecimentos também representam uma forma de controle de parâmetros adaptativo e populacional.

As influências dos conhecimentos Normativo e Situacional/Normativo dependem dos valores dos genes nos quais eles estão sendo aplicados, mais especificamente, é adaptada a posição relativa que o valor do gene tem com relação ao intervalo normativo. A adaptação da forma exata de aplicação das influências (ver as Seções 5.4.2 e 5.4.3) correspondem a um controle automático adaptativo e de gene.

Como pode ser evidenciado nessa seção, o algoritmo proposto é capaz de controlar automaticamente quase todos os seus parâmetros, os únicos parâmetros que precisam ser determinados a priori são o tamanho da população e o valor de alfa, que é a ponderação na função objetivo.

Simulações e Resultados

Para validar o método proposto, ele foi aplicado a três casos extraídos da literatura e utilizados em (SAMED, 2004). Os casos utilizados foram:

- Caso de 3 geradores para o problema do despacho econômico;
- Caso de 13 geradores para o problema do despacho econômico;
- Caso de 6 geradores para o problema do despacho econômico/ambiental.

Para todos os casos foram utilizados os seguintes conjuntos de parâmetros determinados de maneira empírica:

1. Tamanho da população igual a 100;
2. Taxa de cruzamento inicial igual a 90%;
3. Taxa de mutação inicial igual a 10%;
4. Taxa de aceitação igual a 20%;

5. Probabilidade inicial de influência pelo Conhecimento Situacional igual a 33,33%;
6. Probabilidade inicial de influência pelo Conhecimento Normativo igual a 33,33%;
7. Probabilidade inicial de influência pelo Conhecimento Situacional/Normativo igual a 33,33%;
8. Número de melhores indivíduos armazenados no Conhecimento Situacional igual a 10;
9. Critério de parada igual a 3000 gerações sem melhorias no valor de aptidão do melhor indivíduo ¹.

Como afirmado no capítulo anterior, os parâmetros de 2 a 7 são ajustados automaticamente ao longo da evolução e possuem pouca influência nos resultados finais obtidos pelo algoritmo, conforme pode ser observado nas seções seguintes.

Todos os resultados encontrados nesse trabalho serão comparados com aqueles obtidos em (SAMED, 2004). Em (SAMED, 2004) são proposto dos Algoritmos Genéticos Híbridos: um com Co-Evolução de alguns parâmetros e outro sem.

6.1 Despacho Econômico

Nessa seção são abordados problemas que envolvem apenas a minimização dos custos de produção da energia. Para esses problemas o valor de alfa (α) foi setado como sendo 1.0, ou seja, o valor da aptidão depende apenas das variáveis que medem o custo.

6.1.1 Caso 3 Geradores

O caso de despacho econômico com 3 geradores utilizado nesse trabalho foi inicialmente proposto em (SINHA; CHAKRABARTI; CHATTOPADHYAY, 2003). As características do problema (coeficientes característicos da curva de entrada-saída

¹Para os casos com 3 e 13 geradores foram testados como critério de parada igual a 500, 1000, 3000, 5000 e 10000 gerações sem melhoria.

dos geradores e limites operacionais - potências mínimas e máximas para cada gerador) são apresentadas na Tabela 6.1. Para essa instância do problema, a demanda mínima a ser atendida é igual a 850 MW.

Tabela 6.1: Características do Sistema - Caso 3 Geradores

Gerador	$P_{min}(MW)$	$P_{max}(MW)$	a	b	c
1	100	600	0,001562	7,92	561
2	50	200	0,004820	7,97	78
3	100	400	0,001940	7,85	310

Os resultados obtidos com o Algoritmo Cultural proposto em 50 execuções são sumarizados na Tabela 6.2.

Tabela 6.2: Resultados Obtidos pelo AC - Caso 3 Geradores

Critério de Parada do AC	Melhor Custo	Médio Custo	Pior Custo
500	8.194,44	8.196,24	8.199,29
1000	8.194,52	8.195,62	8.198,03
3000	8.194,47	8.195,30	8.196,78
5000	8.194,40	8.195,30	8.196,77
10000	8.194,40	8.195,06	8196,16

Como pode ser observado, a diferença entre o pior e o melhor valor de custo encontrado com o mesmo critério de parada é muito pequena, o que comprova o bom comportamento assintótico do método proposto para esse problema (ou seja, converge para valores ótimos rapidamente).

Para comparar os resultados obtidos com os diferentes critérios de parada foram realizados testes estatísticos. Inicialmente determinou-se se os dados obedeciam uma distribuição normal através do teste de Lilliefors (ABDI; MOLIN, 2007). Este teste determinou que, com 95% de confiabilidade, os dados não seguem uma distribuição normal. Com isso foi descartada a possibilidade de se utilizar o teste-t ou o teste-z, os quais são comumente aplicados mas exigem que os dados sigam uma distribuição normal. Com isso foi realizado um teste estatístico não paramétrico para determinar se as diferenças entre os resultados obtidos eram significativos ou não. O teste utilizado foi o *Mann-Whitney ranksum test*, também conhecido por *Wilcoxon ranksum test* (CONOVER, 1980).

Os testes foram realizados para verificar o impacto da variação do critério de parada. Segundo o teste estatístico com confiabilidade de 95%, não existem diferen-

ças significativas entre o AC com 500 ou com 1000 gerações sem melhoria. Contudo, existe uma diferença significativa entre o Algoritmo Cultural com 3000 e 10000 gerações sem melhoria da aptidão do melhor indivíduo. O uso de 10000 execuções sem melhoria traz uma pequena melhoria nos resultados, porém o tempo computacional despendido é muito superior ao despendido com o uso de 3000. Com isso, acredita-se que a versão que possui o melhor custo benefício é a versão com o critério de parada de 3000 gerações sem melhorias e será essa a versão utilizada na comparação com os demais algoritmos propostos na literatura.

Nas Tabelas 6.3 e 6.4 o resultado obtido com o Algoritmo Cultural é comparado com os melhores resultados obtidos em (SAMED, 2004) (AGH e AGHCOE) e (SINHA; CHAKRABARTI; CHATTOPADHYAY, 2003) (esse último utiliza um Algoritmo Genético com elitismo e penalidade - AG + E + P).

Tabela 6.3: Alocação das Potências - Caso 3 Geradores

Resultados	$P_1(MW)$	$P_2(MW)$	$P_3(MW)$	$P_{total}(MW)$
AGH	470,8421	109,4012	269,7567	850,0000
AGHCOE	344,7295	193,9445	311,3260	850,0000
AG + E + P	393,112	122,252	334,636	850,000
AC - 3000	389,0240	122,8118	338,1710	850,0069

Tabela 6.4: Melhor Valor de Custo Obtidos pelos AGs e pelo AC - Caso 3 Geradores

Resultados	Valor da Função Objetivo (\$/h)
AGH	8.045,51
AGHCOE	7.961,58
AG + E + P	8.194,36
AC - 3000	8.194,47

Conforme é evidenciado nessas tabelas, o resultado atingido pelo AC proposto é muito próximo àquele obtido em (SINHA; CHAKRABARTI; CHATTOPADHYAY, 2003) e inferior àqueles obtidos em (SAMED, 2004). As médias e os piores valores obtidos pelos algoritmos não puderam ser comparados porque os referidos trabalhos não apresentam tais valores.

A Figura 6.1 apresenta o comportamento do algoritmo proposto com relação à média dos indivíduos encontrados geração a geração. Nessa Figura fica evidente que para algumas gerações o custo apresentado é menor do que o custo mínimo apresentado na Tabela 6.2, isso ocorre porque a população fica oscilando entre indivíduos factíveis e infactíveis (que possuem um custo menor). Estudos anteriores (COELLO;

BECERRA, 2002) comprovam que normalmente os melhores valores encontram-se na fronteira de factibilidade do espaço de busca, ou seja, o algoritmo está explorando boas regiões do espaço de busca.

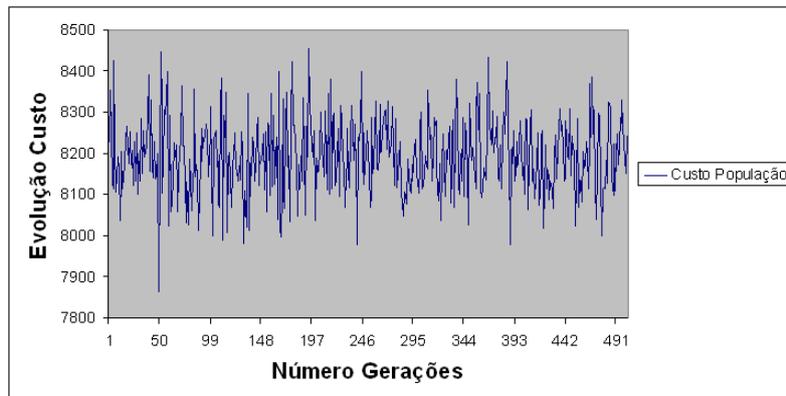


Figura 6.1: Caso 3 Geradores - Gráfico da média inicial de custo do melhor indivíduo.

A Figura 6.2 apresenta a evolução geração a geração do melhor indivíduo encontrado até aquela geração. Pode-se observar que o algoritmo converge rapidamente para as boas soluções.

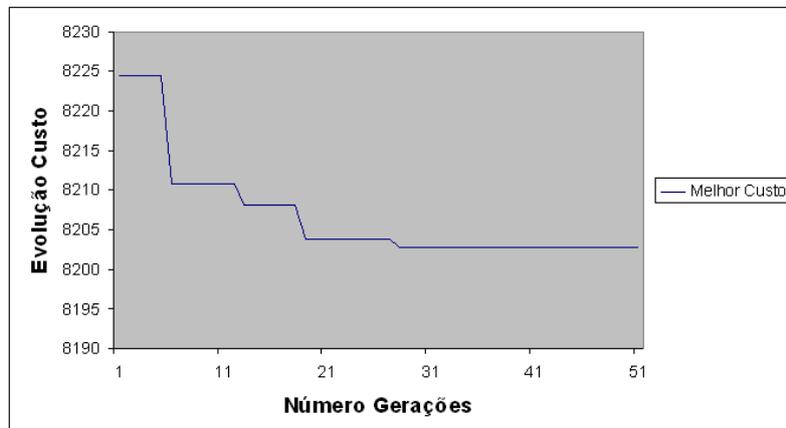


Figura 6.2: Caso 3 Geradores - Gráfico dos melhores custos do melhor indivíduo.

A evolução da taxa de mutação e de cruzamento ao longo das gerações é apresentada na Figura 6.3. Ela demonstra que o algoritmo é capaz de rapidamente encontrar um bom equilíbrio entre as taxas de mutação e cruzamento e após isso oscila suavemente num intervalo pequeno ao redor desse valor.

A Figura 6.4 apresenta a evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento. Como pode ser constatado há uma

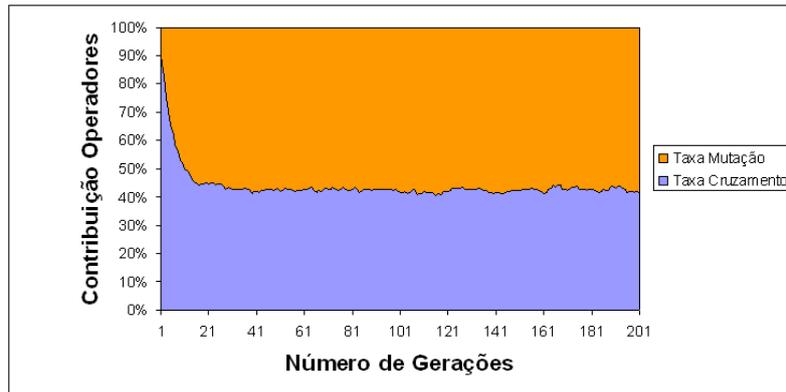


Figura 6.3: Caso 3 Geradores - Gráfico do início da evolução dos operadores de Mutação e Cruzamento.

preponderância das funções de influência dos conhecimentos Situacional e Situacional/Normativo, mas ainda assim a probabilidade da influência do Conhecimento Normativo é significativa ao longo de toda a evolução. Um outro fator importante a ser destacado são as grandes oscilações que ocorrem conforme os conhecimentos vão sendo atualizados e que essas oscilações ocorrem ao longo de todo processo evolutivo, sinalizando que o AC proposto é capaz de se adaptar às modificações do espaço de crenças.

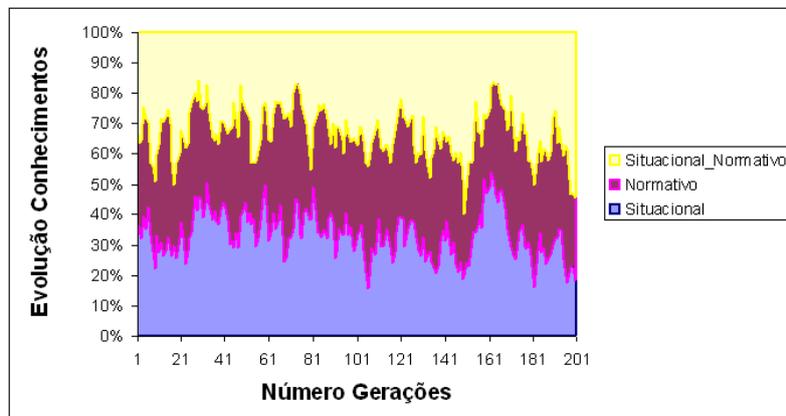


Figura 6.4: Caso 3 Geradores - Gráfico do início da evolução dos Conhecimentos.

6.1.2 Caso 13 Geradores

O caso de despacho econômico com 13 geradores utilizado nesse trabalho é aquele proposto em (KIM et al., 2002). As características do problema são apresentadas na Tabela 6.5.

Tabela 6.5: Características do Sistema - Caso 13 Geradores

Gerador	$P_{min}(MW)$	$P_{max}(MW)$	a	b	c
1	0	680	0,00028	8,10	550
2	0	360	0,00056	8,10	309
3	0	360	0,00056	8,10	307
4	60	180	0,00324	7,74	240
5	60	180	0,00324	7,74	240
6	60	180	0,00324	7,74	240
7	60	180	0,00324	7,74	240
8	60	180	0,00324	7,74	240
9	60	180	0,00324	7,74	240
10	40	120	0,00284	8,60	126
11	40	120	0,00284	8,60	126
12	55	120	0,00284	8,60	126
13	55	120	0,00284	8,60	126

A Tabela 6.6 apresenta os resultados obtidos com 50 execuções do Algoritmo Cultural proposto.

Tabela 6.6: Resultados Obtidos pelo AC - Caso 13 Geradores

Critério de Parada do AC	Melhor Custo	Médio Custo	Pior Custo
500	24.053,15	24.064,41	24.098,02
1000	24.053,10	24.059,09	24.079,51
3000	24.052,10	24.056,61	24.064,33
5000	24.052,21	24.055,28	24.060,09
10000	24.051,45	24.053,88	24.057,60

Pode perceber-se que a diferença entre os melhores e os piores resultados obtidos não é muito grande e se estreita conforme o critério de parada aumenta. Novamente, foram aplicados testes estatísticos para aferir se as diferenças entre os resultados encontrados são significativas. A versão que encontrou melhores resultados foi a que adotou 10000 gerações sem melhorias do melhor valor para a função objetivo como critério de parada. Contudo, essa versão demanda muito mais tempo do que a versão que adota 3000, a qual obtém resultados próximos e foi escolhida como sendo a versão a ser adotada para a comparação com os algoritmos da literatura.

Nas Tabelas 6.7 e 6.8 o resultado obtido com o Algoritmo Cultural é comparado com os melhores resultados obtidos em (SAMEDI, 2004) (AGH e AGHCOE) e (KIM et al., 2002) (esse último utiliza um Algoritmo Genético com geração elitista à parte e atavismo - GA + GE + AT).

Tabela 6.7: Alocação das Potências - Caso 13 Geradores

Resultados	AGH	AGHCOE	AC
$P_1(MW)$	651,1452	735,6263	679,2551
$P_2(MW)$	319,9820	337,4955	359,8672
$P_3(MW)$	320,4637	292,6257	357,2368
$P_4(MW)$	137,7761	146,7135	154,8137
$P_5(MW)$	156,6884	177,3462	158,0946
$P_6(MW)$	147,0077	131,5521	155,8520
$P_7(MW)$	159,1650	154,1975	149,1697
$P_8(MW)$	145,3784	159,5506	146,8364
$P_9(MW)$	151,5512	167,3398	168,7979
$P_{10}(MW)$	82,2596	60,6778	40,0181
$P_{11}(MW)$	86,3206	74,6819	40,0000
$P_{12}(MW)$	82,8938	56,5370	55,0175
$P_{13}(MW)$	79,3682	25,6558	55,0488
$P_{total}(MW)$	2.520,0000	2.520,0000	2.520,0084

Tabela 6.8: Melhor Valor de Custo - Caso 13 Geradores

Resultados	Valor da Função Objetivo (\$/h)
AGH	24.111,69
AGHCOE	24.072,03
GA + GE + AT	24.052,34
AC - 3000	24.052,10

Como pode ser observado, os resultados obtidos pelo Algoritmo Cultural proposto e pelo GA + GE + AT são bastante próximos, sendo que o do AC é melhor. Quando comparado ao AGH e ao AGHCOE, a diferença é ainda mais acentuada em favor do AC.

Como em (KIM et al., 2002) também são fornecidos os valores médios e os piores valores obtidos, é possível fazer uma comparação mais detalhada entre o Algoritmo Cultural proposto e o GA + GE + AT. A Tabela 6.9 realiza essa comparação. Pode-se concluir que, apesar dos melhores resultados serem próximos, os resultados médios e o pior resultado obtidos pelo AC são significativamente superiores aos obtidos pelo GA + GE + AT, ou seja, pode-se dizer que o comportamento médio do AC é melhor do o comportamento médio do GA + GE + AT.

Tabela 6.9: Comparação dos Melhores Custos Obtidos pelo AC e pelo GA+GE+AT - Caso 13 Geradores

	Melhor	Médio	Pior
GA + GE + AT	24.052,34	24.065,41	24.090,34
AC - 3000	24.052,10	24.056,61	24.064,33

A Figura 6.5 mostra que o algoritmo alterna a exploração entre indivíduos factíveis e infactíveis próximos ao valor sub-ótimo encontrado.

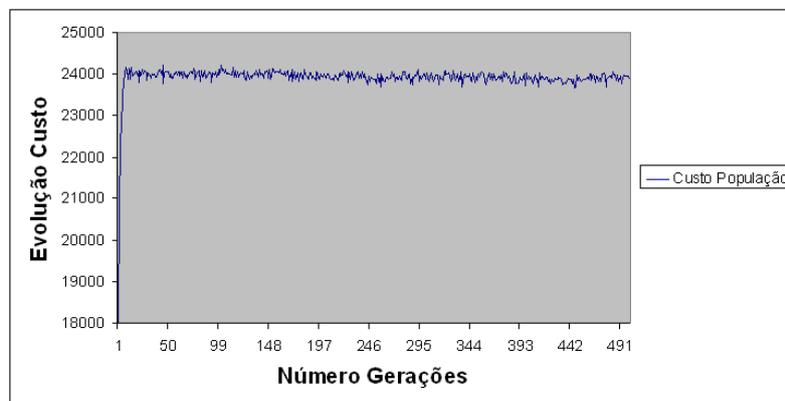


Figura 6.5: Caso 13 Geradores - Gráfico da média inicial de custo do melhor indivíduo.

Outra vez, o Algoritmo Cultural começa encontrando somente indivíduos infactíveis e, quando consegue encontrar indivíduos factíveis, converge rapidamente para bons valores. A Figura 6.6 mostra a evolução do melhor indivíduo encontrado até o momento. Em poucas gerações o algoritmo converge para boas soluções.

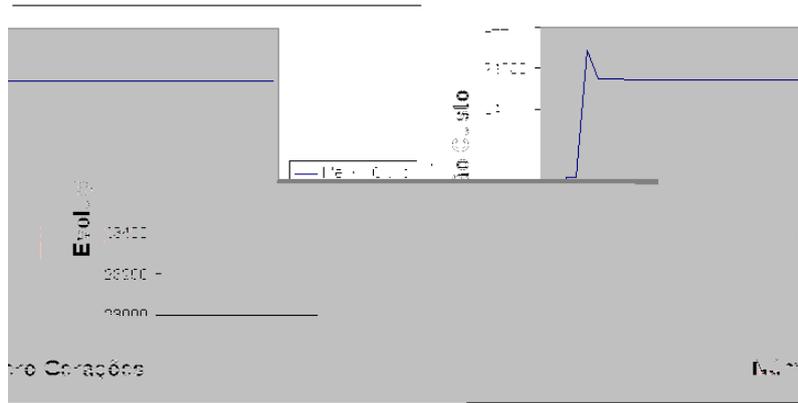


Figura 6.6: Caso 13 Geradores - Gráfico dos melhores custos do melhor indivíduo.

Na Figura 6.7, pode-se constatar que o ajuste das taxas de mutação e cruzamento convergem rapidamente para seus valores ótimos, sofrendo leves oscilações após isso.

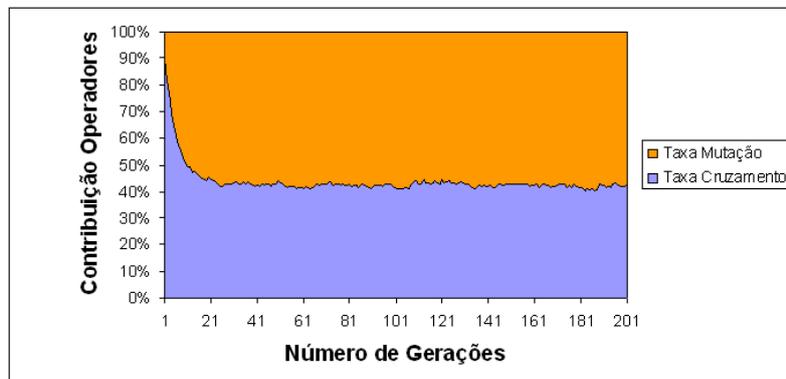


Figura 6.7: Caso 13 Geradores - Gráfico do início da evolução dos operadores de Mutação e Cruzamento.

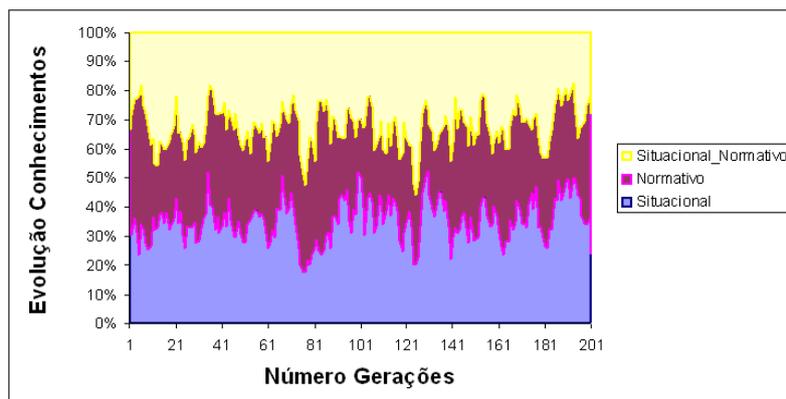


Figura 6.8: Caso 13 Geradores - Gráfico do início da evolução dos Conhecimentos.

Conforme demonstrado na Figura 6.8, há uma predominância do uso das funções

de influência dos conhecimentos Situacional e Situacional/Normativo, contudo a contribuição do Conhecimento Normativo é significativa.

6.2 Despacho Econômico/Ambiental

O Despacho Econômico/Ambiental é um problema multi-objetivo e como tal não possui uma solução única. Os experimentos realizados visaram aproximar uma curva de soluções ótimas (chamada de Fronteira de Pareto). Para isso o valor de α foi variado de 0 a 1 com um intervalo de 0,1. O caso onde α é igual a 0 corresponde ao Despacho Ambiental enquanto o caso com α igual a 1 corresponde ao Despacho Econômico, valores intermediários correspondem a um compromisso entre o custo de produção e a emissão de poluentes.

Como o critério de parada adotado para ambos os casos do Despacho Econômico foi 3000 gerações de estagnação, ele será utilizado também para o caso do Despacho Econômico/Ambiental.

6.2.1 Caso 6 Geradores

O caso de Despacho Econômico/Ambiental com 6 geradores utilizado nesse trabalho é aquele proposto em (SAMED, 2004). As características do problema são apresentadas nas Tabelas 6.10 e 6.11.

Tabela 6.10: Características do Sistema - Caso 6 Geradores

Gerador	Função Custo			Função Emissão		
	a	b	c	A	B	C
1	0,15247	38,53973	756,79886	0,00419	0,32767	13,85932
2	0,10587	46,15916	451,32513	0,00419	0,32767	13,85932
3	0,02803	40,39655	1049,9977	0,00683	-0,54551	40,2669
4	0,03546	38,30553	1243,5311	0,00683	-0,54551	40,2669
5	0,02111	36,32782	1658,5696	0,00461	-0,51116	42,89553
6	0,01799	38,27041	1356,6592	0,00461	-0,51116	42,89553

A Tabela 6.12 apresenta os valores ótimos (Melhor), médios (Médio) e os piores (Pior) obtidos pelo AC para α variando entre 0.0 e 1.0.

Tabela 6.11: Limites Operacionais - Caso 6 Geradores

Gerador	$P_{min}(MW)$	$P_{max}(MW)$
1	10	125
2	10	150
3	35	225
4	35	210
5	130	325
6	125	315

Tabela 6.12: Resultados Obtidos pelo AC - Caso 6 Geradores

α	Melhor	Médio	Pior
0.0	255,96	256,52	257,04
0.1	2.942,61	2.943,88	2.945,99
0.2	5619,53	5621,14	5624,99
0.3	8.294,18	8.295,90	8300,07
0.4	10.968,43	10.970,41	10.978,21
0.5	13.641,46	13.646,43	13.670,02
0.6	16.314,45	16.319,00	16.331,74
0.7	18.986,99	18.992,35	19.008,04
0.8	21.660,20	21.667,94	21.694,14
0.9	24.332,22	24.343,10	24.442,45
1.0	27.003,95	27.013,33	27.042,83

As Tabelas 6.13 e 6.14 mostram os melhores valores obtidos para os geradores para cada um dos valores de α utilizados.

Tabela 6.13: Alocação das Potências pelo AGHCOE - Caso 6 Geradores - DEA

α	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆	P _{total}
0,0	32,8840	38,4133	82,3074	85,2323	135,000	126,162	500,0
0,1	31,1802	27,9616	82,0160	81,9334	149,548	127,360	500,0
0,2	32,6486	19,8177	76,7812	77,1505	156,241	137,360	500,0
0,3	27,1615	21,9804	80,0643	74,1930	158,282	138,318	500,0
0,4	28,9582	20,0708	80,3485	71,0486	155,099	144,474	500,0
0,5	28,7291	19,2459	78,0281	72,4858	157,879	143,631	500,0
0,6	22,6986	18,9907	72,4348	77,2391	158,429	150,207	500,0
0,7	23,6043	17,0307	69,6938	85,8202	169,733	134,117	500,0
0,8	19,9521	17,9735	69,0478	79,0580	171,809	142,159	500,0
0,9	24,0853	15,0439	69,3953	80,8028	178,840	131,832	500,0
1,0	20,1367	14,8645	72,4007	72,9497	180,061	139,586	500,0

Tabela 6.14: Alocação das Potências pelo AC - Caso 6 Geradores - DEA

α	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆	P _{total}
0,0	36,1087	36,1111	87,8129	84,9723	130,0078	125,0000	500,0
0,1	22,2518	10,0000	83,5540	88,4117	151,8228	143,9640	500,0
0,2	19,6071	10,0861	79,5031	86,7386	158,4355	145,6437	500,0
0,3	19,5708	10,0000	72,8695	82,9713	164,9703	149,6200	500,0
0,4	19,5062	10,0000	71,0872	85,8347	168,7099	144,8984	500,0
0,5	18,6701	10,0001	70,1451	80,9406	171,1028	149,1438	500,0
0,6	17,8382	10,0092	65,5474	80,5261	175,7406	150,3427	500,0
0,7	19,1287	10,0000	63,7766	79,2157	173,5360	154,3436	500,0
0,8	18,9179	10,0097	62,6074	79,5272	180,3892	148,5492	500,0
0,9	18,1274	10,0000	62,1811	74,6337	176,5979	158,4612	500,0
1,0	18,0581	10,0030	63,0161	76,3844	178,3528	154,1898	500,0

Nas Tabelas 6.15 e 6.16 o resultado obtido com o Algoritmo Cultural é comparado com os melhores resultados obtidos em (SAMED, 2004) (AGHCOE).

Na primeira tabela pode-se notar que o valor de custo obtido pelo AC é menor do que o obtido pelo AGHCOE para todos os valores de α exceto 0.0. Esse valor corresponde ao Despacho Ambiental, o qual ignora o valor de custo, e nesse caso o valor de emissão obtido pelo AC é menor do que o obtido pelo AGHCOE. Esses resultados demonstram que o AC prioriza o custo para valores de α iguais ou superiores a 0.1, o que realmente deve ser feito visto que o custo contribui mais do que a emissão para o valor da função objetivo. No que tange a função objetivo a Tabela 6.16 evidencia que os valores da função objetivo obtidos pelo Algoritmo Cultural proposto são sem-

Tabela 6.15: Custo e Emissão do AGHCOE e do AC - Caso 6 Geradores - DEA

α	Custo AGHCOE (\$/h)	Custo AC (\$/h)	Emissão AGHCOE (kg/h)	Emissão AC (kg/h)
0,0	27.319,3	27.331,2	256,360	255,960
0,1	27.191,5	27.041,3	259,460	264,978
0,2	27.114,8	27.026,6	263,735	267,754
0,3	27.109,7	27.012,8	264,575	271,886
0,4	27.104,0	27.014,1	265,284	272,658
0,5	27.092,7	27.007,8	266,030	275,000
0,6	27.068,0	27.004,9	268,270	278,768
0,7	27.059,0	27.004,6	269,970	279,225
0,8	27.051,9	27.004,8	272,707	281,472
0,9	27.046,9	27.004,3	274,930	283,133
1,0	27.037,2	27.003,9	276,894	282,212

Tabela 6.16: Valor da Função Objetivo do AGHCOE e do AC - Caso 6 Geradores - DEA

α	Função Objetivo AGHCOE	Função Objetivo AC
0,0	256,360	255,960
0,1	2952,664	2942,615
0,2	5633,948	5619,53
0,3	8318,112	8294,185
0,4	11000,770	10968,432
0,5	13679,365	13641,461
0,6	16348,108	16314,447
0,7	19022,291	18986,987
0,8	21696,061	21660,134
0,9	24369,703	24332,183
1,0	27037,200	27003,953

pre melhores do que aqueles obtidos pelo AGHCOE, comprovando a superioridade do método para essa instância particular do Despacho Econômico/Ambiental.

As Figuras 6.9 e 6.10 apresentam o comportamento das médias de custo e emissão, respectivamente, para as primeiras gerações do processo evolutivo quando o valor de α é igual a 0.0. Em ambas as figuras pode-se observar que os valores começam distantes dos valores ótimos, mas se aproximam dos mesmos rapidamente.

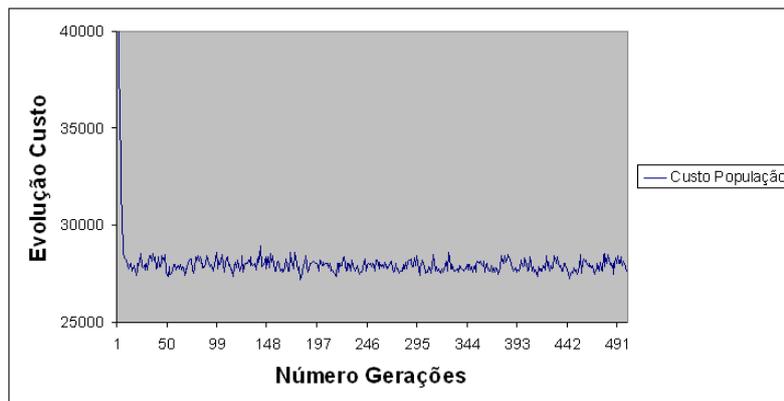


Figura 6.9: Caso 6 Geradores - alfa 0.0 - Gráfico da média de custo.

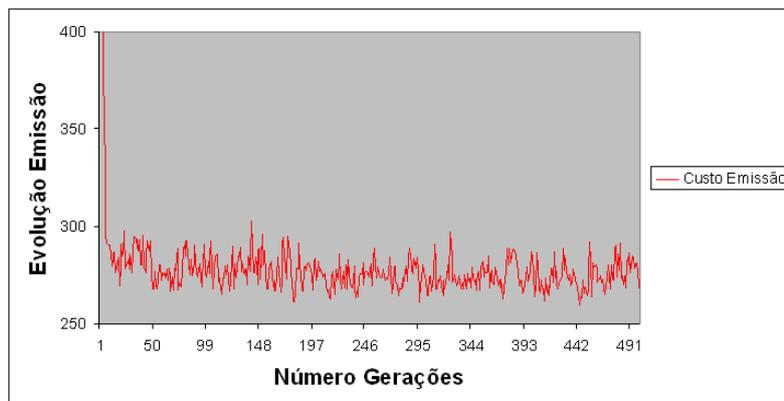


Figura 6.10: Caso 6 Geradores - alfa 0.0 - Gráfico da média de emissões.

Já as Figuras 6.11 e 6.12 permitem observar o comportamento dos melhores valores obtidos durante as primeiras gerações. É possível notar que os valores também se iniciam distantes dos valores ótimos, mas convergem rapidamente.

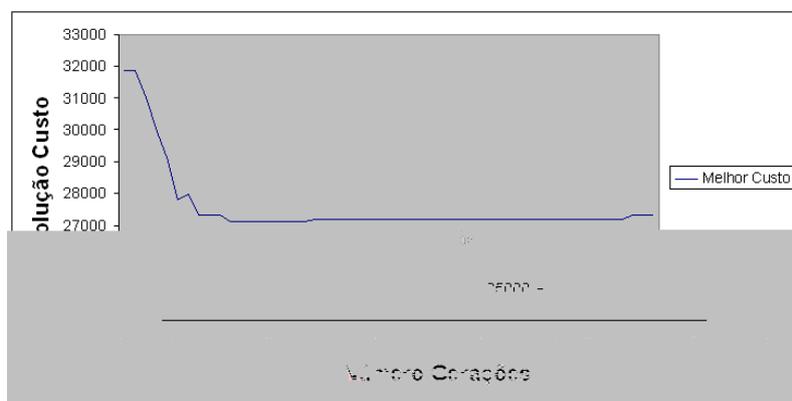


Figura 6.11: Caso 6 Geradores - alfa 0.0 - Gráfico dos melhores custos.

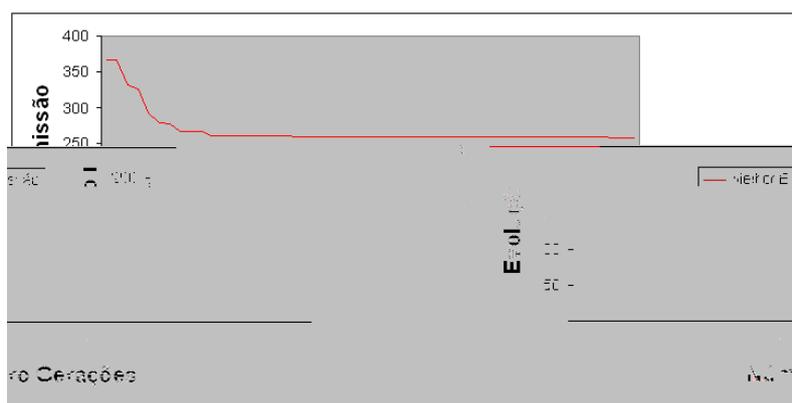


Figura 6.12: Caso 6 Geradores - alfa 0.0 - Gráfico das melhores emissões.

A evolução das taxas de mutação e cruzamento é sumarizada na Figura 6.13. Novamente é possível observar que as taxas convergem rapidamente, estabilizando num patamar entre 40 e 50%.

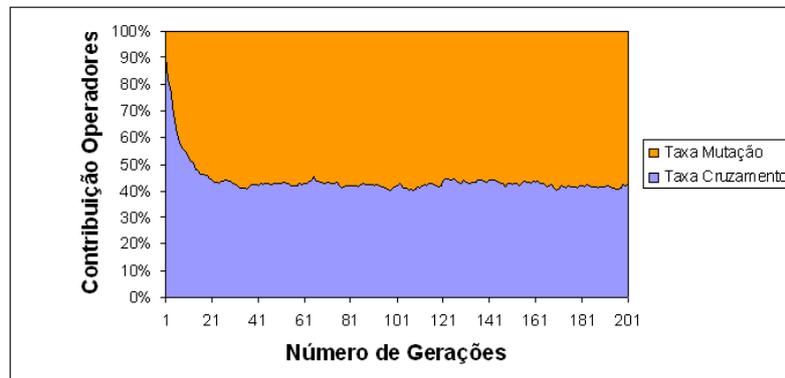


Figura 6.13: Caso 6 Geradores - alfa 0.0 - Gráfico da evolução dos operadores de Mutação e Cruzamento.

A probabilidade de aplicação dos diferentes tipos de conhecimento são mostrados na Figura 6.14. As funções de influência dos conhecimentos Situacional e Situacional/Normativo novamente ocorrem a taxas maiores do que as funções de influência do Conhecimento Normativo, sendo que a probabilidade do Conhecimento Normativo é significativa.

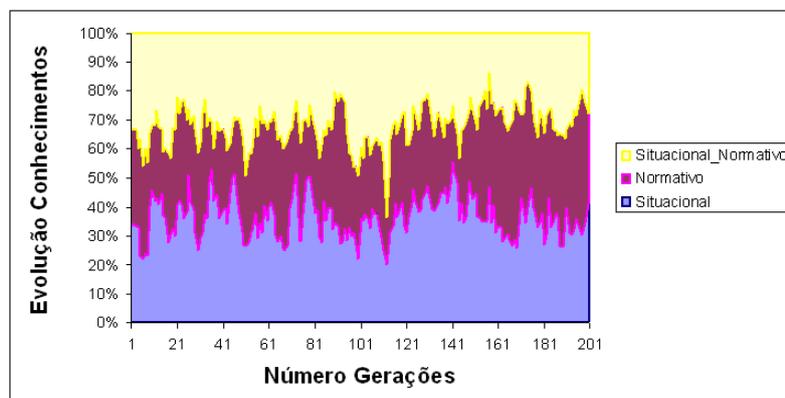


Figura 6.14: Caso 6 Geradores - alfa 0.0 - Gráfico do início da evolução dos Conhecimentos.

O comportamento do algoritmo proposto para os demais valores de α são praticamente idênticos e não são aqui demonstrados para evitar redundâncias desnecessárias.

As Figuras 6.15 e 6.16 apresentam as aproximações encontradas para a Fronteira de Pareto pelo AC e pelo AGHCOE, respectivamente. Pelas figuras é possível

concluir que o AC é capaz de encontrar uma melhor aproximação para a Fronteira de Pareto do que o AGHCOE, o que já poderia ter sido concluído da Tabela 6.16, visto que o AC possui melhores valores para a função de aptidão.

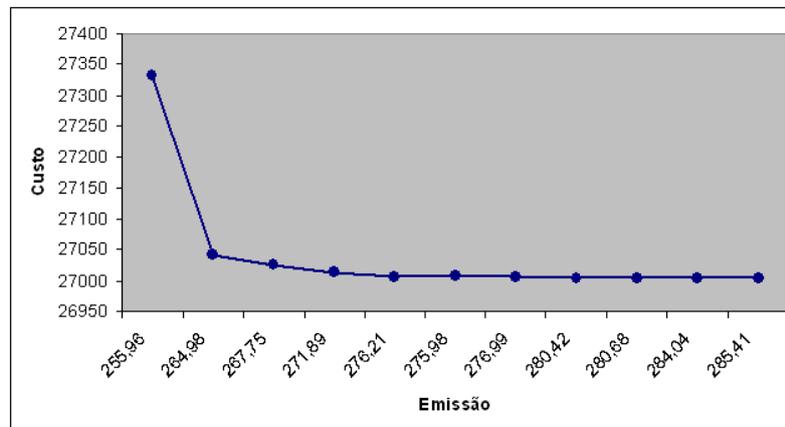
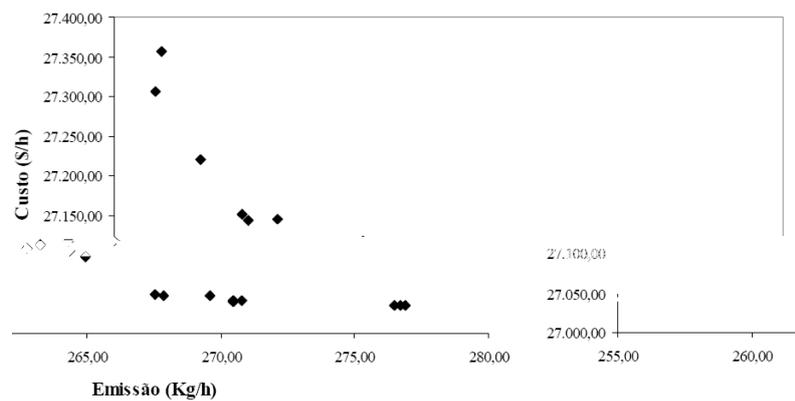


Figura 6.15: Aproximação da Fronteira de Pareto Obtida pelo AC.



Conclusões e Trabalhos Futuros

7.1 Conclusões

Esse trabalho apresentou uma abordagem baseada em Algoritmos Culturais e Algoritmos Genéticos para o problema do Despacho Econômico e do Despacho Econômico/Ambiental. Os resultados obtidos pela abordagem proposta são comparáveis e em alguns casos superiores àqueles publicados na literatura, demonstrando o bom comportamento do algoritmo.

Infelizmente, a maioria dos trabalhos da área apresentam apenas os melhores valores obtidos pelas técnicas propostas, dificultando as comparações entre as técnicas. No único caso onde esse tipo de comparação foi possível o comportamento do algoritmo proposto foi superior ao do algoritmo reportado na literatura (tanto no melhor caso, quanto no caso médio e no pior caso), mais uma vez atestando a eficiência do método proposto.

O Algoritmo Cultural proposto possui alguns pontos de adaptação como as taxas de aplicação das funções de influência, probabilidade de uso de mutação ou cruzamento e taxa de aceitação. Acredita-se que as adaptações de parâmetros propostas

mostraram-se eficientes, visto que os resultados obtidos foram bons.

7.2 Trabalhos Futuros

Como principais trabalhos futuros propõe-se:

- **Outros tipos de conhecimento:** nesse trabalho foram utilizados três tipos de conhecimentos, sendo que existem outros que seriam interessantes de serem utilizados na resolução de problemas de despacho de energia, tais como o Conhecimento Histórico e o Conhecimento Topográfico;
- **Hibridização:** apesar dos Algoritmos Culturais serem híbridos por natureza, seria interessante estudar-se a hibridização com outros métodos, tais como os métodos quasi-simplex e SQP (Sequential Quadratic Programming);
- **Outras populações:** apesar dos Algoritmos Genéticos serem bastante eficientes e serem comprovadamente bons algoritmos para a resolução do problema do despacho, outras técnicas, como as Estratégias Evolutivas e a Programação Evolutiva, poderiam ser utilizadas no espaço populacional;
- **Ponto de Válvula:** trabalhos futuros poderiam utilizar a versão mais real da função que representa o custo do despacho introduzindo os termos de ponto de válvula e, talvez, restrições de segurança da rede elétrica e perdas de energia durante o despacho;
- **Ajuste da adaptação:** outras técnicas/fórmulas de adaptação dos parâmetros poderiam ser testadas na busca de tornar esse ajuste ainda melhor.

Referências Bibliográficas

- ABDI, H.; MOLIN, P. Lilliefors test of normality. In: SALKIND, N. (Ed.). *Encyclopedia of Measurement and Statistics*. Thousand Oaks, CA, USA: Sage Publications, 2007.
- BECERRA, R. L. *Algoritmos Culturales Aplicados a Optimización con Restricciones y Optimización Multiobjetivo*. Tese (Doutorado) — Instituto Politécnico Nacional do México, 2002.
- BECERRA, R. L.; COELLO, C. A. C. Optimization with constraints using a cultured differential evolution approach. In: *Genetic and Evolutionary Computation Conference*. [S.l.: s.n.], 2005. p. 27–34.
- COELHO, L. S. *Fundamentos, Potencialidades e Aplicações de Algoritmos Evolutivos*. [S.l.]: SBMAC, 2003.
- COELLO, C. A.; BECERRA, R. L. Adding knowledge and efficient data structures to evolutionary programming: A cultural algorithm for constrained optimization. In: LANGDON E. CANTÚ-PAZ, K. M. R. R. D. D. R. P. K. B. V. H. G. R. J. W. L. B. M. A. P. A. S. J. F. M. E. B. W.; N. JONOSKA (Ed.). *Proceedings of the Genetic and Evolutionary Computation Conference*. San Francisco, California: Morgan Kaufmann Publishers, 2002. p. 201–209.
- CONOVER, W. J. *Practical Nonparametric Statistics*. USA: John Wiley & Sons, 1980.
- DAMOUSIS, I. G.; BAKIRTZIS, A. G.; DOKOPOULOS, P. S. Network-constrained economic dispatch using real-coded genetic algorithm. *IEEE Transactions on Power Systems*, v. 18, n. 1, p. 198 – 205, February 2003.
- EIBEN, A. E.; HINTERDING, R.; MICHALEWICZ, Z. Parameter control in evolutionary algorithms. *IEEE Trans. on Evolutionary Computation*, v. 3, n. 2, p. 124–141, 1999. Disponível em: <citeseer.ist.psu.edu/article/eiben00parameter.html>.

- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. [S.l.]: Addison Wesley Longman, 1989.
- HINTERDING; MICHALEWICZ; EIBEN. Adaptation in evolutionary computation: A survey. In: *IEEECEP: Proceedings of The IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence*. [s.n.], 1997. Disponível em: <citeseer.ist.psu.edu/hinterding97adaptation.html>.
- IACOBAN, R.; REYNOLDS, R.; BREWSTER, J. Cultural swarms: assessing the impact of culture on social interaction and problem solving. In: *IEEE Swarm Intelligence Symposium*. [S.l.: s.n.], 2003. p. 212–219.
- IACOBAN, R.; REYNOLDS, R.; BREWSTER, J. Cultural swarms: modeling the impact of culture on social interaction and problem solving. In: *IEEE Swarm Intelligence Symposium*. [S.l.: s.n.], 2003. p. 205–211.
- JIN, X.; REYNOLDS, R. G. Using knowledge-based evolutionary computation to solve nonlinear constraint optimization problems: a cultural algorithm approach. *IEEE*, p. 1672 – 1678, 1999.
- JIN, X.; REYNOLDS, R. G. Using knowledge-based system with hierarchical architecture to guide the search of evolutionary computation. *Tools with Artificial Intelligence - 11th IEEE International Conference*, p. 29–36, 1999.
- KIM, J. O. et al. Atavistic genetic algorithm for economic dispatch with valve point effect. *Electric Power Systems Research*, v. 62, p. 201 – 207, 2002.
- KNUTH, D. E. *The Art of Computer Programming*. [S.l.]: Addison-Wesley Professional, 1998.
- LACERDA, E. G. M.; CARVALHO, A. C. P. L. *Sistemas Inteligentes: Aplicações a Recursos Hídricos e Ciências Ambientais*. 1999. Capítulo: Introdução aos Algoritmo Genéticos.
- LUCAS, D. C. *Algoritmos Genéticos: Um Estudo de Seus Conceitos Fundamentais e Aplicação no Problema de Grade Horária*. 2000. Universidade Federal de Pelotas.
- MOHAMMADI, A.; VARAHRAM, M. H. Using neural network for solving of on-line economic dispatch problem. *IEEE - International Conference on Computational Intelligence for Modelling Control and Automation, and International Conference on Intelligent Agents, Web Technologies and Internet Commerce*, 2006.
- PENG, B.; REYNOLDS, R. G.; BREWSTER, J. Cultural swarms. *IEEE*, 2003.
- PÉREZ-GUERRERO, R. E.; CEDEÑO-MALDONADO, J. R. Differential evolution based economic environmental power dispatch. *IEEE*, 2005.
- REYNOLDS, R.; PENG, B.; BREWSTER, J. Cultural swarms ii: virtual algorithm emergence. In: *Congress on Evolutionary Computation*. [S.l.: s.n.], 2003. v. 3, p. 1972–1979.

- REYNOLDS, R.; ZHU, S. Knowledge-based function optimization using fuzzy cultural algorithms with evolutionary programming. *IEEE Transactions on Systems, Man and Cybernetics - Part B*, v. 31, n. 1, p. 1–18, 2001.
- REYNOLDS, R. G. An introduction to cultural algorithm. In: *3rd Annual Congerence on Evolutionary Programming*. [S.l.: s.n.], 1994.
- REYNOLDS, R. G. Advances in evolutionary computation. In: _____. [S.l.]: McGraw Hill Press, 1999. cap. An Overview of Cultural Algorithms.
- REYNOLDS, R. G. Knowledge swarms and cultural evolution. In: *Proceedings of American Anthropological Association Annual Meeting*. [S.l.: s.n.], 2001a.
- REYNOLDS, R. G. *Cultural and Social Evolution in Dynamic Environments*. 2001b. CASOS 2001.
- REYNOLDS, R. G. *Tutorial on Cultural Algorithms*. 2003. IEEE Swarm Intelligence Symposium.
- REYNOLDS, R. G.; CHUNG, C. Fuzzy approaches to acquiring experimental knowledge in cultural algorithms. *IEEE*, p. 260 – 267, 1997.
- REYNOLDS, R. G.; ZANONI, E. Why cultural evolution can proceed faster than biological evolution. In: *Proceedings of International Symposium on Simulating Societies*. [S.l.: s.n.], 1992. p. 81–93.
- SAMED, M. M. A. *Um Algoritmo Genético Híbrido Co-Evolutivo para Resolver Problemas de Despacho*. Tese (Doutorado) — UEM, 2004.
- SAMED, M. M. A.; RAVAGNANI, M. A. S. S.; GOMES, R. Um algoritmo genético híbrido aplicado ao problema do despacho econômico. In: CLAGTEE. *V Latin-American Congress: Electricity Generation and Transmission*. Águas de São Pedro, SP, BR, 2003.
- SHEBLE, G. B.; BRITTIG, K. Refined genetic algorithm - economic dispatch example. *IEEE Transactions on Power Systems*, v. 10, n. 1, p. 117 – 124, February 1995.
- SILVA, I. N.; NEPOMUCENO, L.; BASTOS, T. M. Resolvendo problemas de fluxo de potência Ótimo dc através de uma rede de hopfield modificada. *Revista Controle e Automação*, v. 15, n. 4, p. 423–436, Outubro, Novembro e Dezembro 2004.
- SINHA, N.; CHAKRABARTI, R.; CHATTOPADHYAY, P. K. Evolutionary programming techniques for economic load dispatch. *IEEE Transaction Evolutionary Computation*, v. 7, n. 1, p. 83 – 94, February 2003.
- SONG, Y. H. et al. Environmental/economic dispatch using fuzzy logic controlled genetic algorithms. *IEE*, v. 144, n. 4, p. 377–382, July 1997.
- SOUZA, L. V. *Programação Genética e Combinação de Preditores para Previsão de Séries Temporais*. Tese (Doutorado) — Universidade Federal do Paraná, 2006.

- STERNBERG, M.; REYNOLDS, R. G. Using cultural algorithms to support re-engineering of rule-based expert systems in dynamic performance environments: A case study in fraud detection. *IEEE Transaction on Evolutionary Computation*, v. 1, n. 4, p. 225 – 243, November 1997.
- TAKAHASHI, L. *Abosrdagem de Sistemas Inteligentes para a Solução do Problema de Despacho Econômico de Geração*. 2004. Universidade Estadual Paulista.
- WHITLEY, D. *A Genetic Algorithm Tutorial*. 1998.
- WHITLEY, D. *An Overview of Evolutionary Algorithms: Practical Issues and Common Pitfalls*. 2001.
- WONG, K. P.; YURYEVICH, J. Evolutionary-programming-based algorithm for environmentally-constrained economic dispatch. *IEEE Transactions on Power Systems*, v. 13, n. 2, p. 301–306, May 1998.
- ZHANG, G. et al. A new hybrid real-coded genetic algorithm and application in dynamic economic dispatch. *IEEE - Proceedings of the 6th World Congress on Intelligent Control and Automation*, p. 3627 – 3632, June 2006.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)