

**Universidade Estadual de
Maringá**
Centro de Tecnologia
Departamento de Informática
Curso de Engenharia de Produção

**Extensão de um Algoritmo Cultural para Problemas de
Despacho de Energia Elétrica**

Gislaine Camila Lapasini Leal

TCC-EP-26-2007

Universidade Estadual de Maringá
Centro de Tecnologia
Departamento de Informática
Curso de Engenharia de Produção

**Extensão de um Algoritmo Cultural para Problemas de Despacho de
Energia Elétrica**

Gislaine Camila Lapasini Leal

TG-EP-26-2007

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção, do Centro de Tecnologia, da Universidade Estadual de Maringá.

Orientador(a): *Prof^a. Márcia Marcondes Altimari Samed*

**Maringá - Paraná
2007**

Gislaine Camila Lapasini Leal

Extensão de um Algoritmo Cultural para Problemas de Despacho de Energia Elétrica

Este exemplar corresponde à redação final do Trabalho de Conclusão de Curso aprovado como requisito parcial para obtenção do grau de Bacharel em Engenharia de Produção da Universidade Estadual de Maringá, pela comissão formada pelos professores:

Orientador(a): Prof^a. Márcia Marcondes Altimari Samed
Departamento de Informática, CTC

Prof. José Roberto Vasconcelos
Departamento de Informática, CTC

Maringá, outubro de 2007

DEDICATÓRIA

Dedico este trabalho aos meus pais, pelo amor, dedicação, compreensão e incentivo.

EPÍGRAFE

[...] talvez não tenhamos conseguido fazer o melhor, mas lutamos para que o melhor fosse feito [...] Não somos o que deveríamos ser, mas somos o que iremos ser. Mas graças a Deus, não somos o que éramos Martin Luther King).

AGRADECIMENTOS

A Deus, que sempre esteve comigo neste desafio.

Meus sinceros agradecimentos a minha orientadora Prof^a Márcia Marcondes Altimari Samed, pelo incentivo, confiança, além de agüentar minhas reclamações.

A Natally Rodrigues Macedo, por ter concedido seu trabalho, ter me apoiado e me incentivado nos momentos de fraqueza.

Ao professor Leandro Coelho (PUC-PR) e Ricardo Landa Becerra (Instituto Politecnico Nacional -México) pelas contribuições ao longo deste trabalho.

Ao professor José Roberto Vasconcelos pela presença na banca examinadora.

Aos demais amigos aqui não citados que de alguma forma me ajudaram e incentivaram a prosseguir nessa caminhada.

RESUMO

Palavras-chave: Despacho Econômico, Despacho Ambiental, Algoritmos Genéticos, Algoritmos Culturais, Conhecimento Histórico.

SUMÁRIO

RESUMO	vii
SUMÁRIO	viii
LISTA DE ILUSTRAÇÕES	x
LISTA DE TABELAS	xi
LISTA DE ABREVIATURAS E SIGLAS	xii
LISTA DE SÍMBOLOS	xii
1 INTRODUÇÃO	1
1.1 OBJETIVOS	2
1.1.1 <i>Objetivo Geral</i>	2
1.1.2 <i>Objetivos Específicos</i>	2
1.2 ORGANIZAÇÃO DO TRABALHO.....	2
2 REVISÃO DA LITERATURA	4
2.1 OTIMIZAÇÃO.....	4
2.1.1 <i>Problemas de Otimização em Engenharia de Produção</i>	5
2.1.1.1 Dimensionamento de lotes	6
2.1.1.2 Problema de corte e empacotamento	7
2.1.1.3 Alocação de recursos	7
2.1.1.4 Escalonamento <i>job-shop</i>	8
2.1.1.5 Despacho de Energia Elétrica.....	8
2.2 PERSPECTIVAS DO PROBLEMA DE DESPACHO DE ENERGIA ELÉTRICA	8
2.2.1 <i>Despacho Econômico</i>	9
2.2.1.1 Modelagem do Despacho Econômico	9
2.2.2 <i>Despacho Ambiental</i>	10
2.2.2.1 Modelagem do Despacho Ambiental	10
2.3 ALGORITMOS GENÉTICOS.....	11
2.3.1 <i>Codificação dos indivíduos</i>	13
2.3.1.1 Codificação binária.....	14
2.3.1.2 Codificação Gray.....	14
2.3.1.3 Codificação real.....	15
2.3.2 <i>Geração da população inicial</i>	15
2.3.3 <i>Função de aptidão</i>	16
2.3.4 <i>Operadores genéticos</i>	16
2.3.4.1 Cruzamento	17
2.3.4.2 Mutação.....	18
2.3.5 <i>Seleção de indivíduos</i>	19
2.3.6 <i>Parâmetros do algoritmo genético</i>	20
2.3.7 <i>Critérios de Parada</i>	21
2.4 ALGORITMOS CULTURAIS.....	21
2.4.1 <i>Características</i>	24
2.4.2 <i>Aplicações</i>	25
2.4.3 <i>Categorias de Conhecimento</i>	26
2.4.3.1 Conhecimento Normativo	26
2.4.3.2 Conhecimento Situacional	26
2.4.3.3 Conhecimento Topográfico	27
2.4.3.4 Conhecimento do Domínio	27
2.4.3.5 Conhecimento Histórico.....	28
3 METODOLOGIA PROPOSTA	31
3.1 ESPAÇO POPULACIONAL	34
3.2 ESPAÇO DE CRENÇA.....	34
3.3 CATEGORIAS DE CONHECIMENTO.....	36
3.3.1 <i>Conhecimento Situacional</i>	37
3.3.2 <i>Conhecimento Normativo</i>	37

	ix
3.3.3	<i>Conhecimento Situacional/Normativo</i> 37
3.3.4	<i>Conhecimento Histórico</i> 38
3.4	ADAPTAÇÃO DOS PARÂMETROS 38
4	SIMULAÇÕES E RESULTADOS 41
4.1	DESPACHO ECONÔMICO..... 42
4.1.1	<i>Caso 3 Geradores</i> 42
4.1.2	<i>Caso 13 Geradores</i> 47
4.2	DESPACHO ECONÔMICO/AMBIENTAL..... 53
4.2.1	<i>Caso 6 Geradores</i> 53
	CONCLUSÃO.....63
	REFERÊNCIAS65

LISTA DE ILUSTRAÇÕES

FIGURA 1: REPRESENTAÇÃO DO CRUZAMENTO COM UM PONTO DE CORTE.....	17
FIGURA 2: REPRESENTAÇÃO DO CRUZAMENTO COM DOIS PONTOS DE CORTE.....	18
FIGURA 3: REPRESENTAÇÃO DO CRUZAMENTO COM N ($N=4$) PONTOS DE CORTE.....	18
FIGURA 4: REPRESENTAÇÃO DA MUTAÇÃO.....	19
FIGURA 5: ESTRUTURA DOS ALGORITMOS CULTURAIS (RODRIGUES, 2007).....	24
FIGURA 6: REPRESENTAÇÃO DO CONHECIMENTO NORMATIVO (REYNOLDS ET. AL, 2005).	26
FIGURA 7: REPRESENTAÇÃO DO CONHECIMENTO SITUACIONAL (REYNOLDS ET. AL, 2005).	27
FIGURA 8: REPRESENTAÇÃO DO CONHECIMENTO TOPOGRÁFICO (REYNOLDS ET. AL, 2005).....	27
FIGURA 9: REPRESENTAÇÃO DO CONHECIMENTO DO DOMÍNIO (REYNOLDS ET. AL, 2005).....	28
FIGURA 10: REPRESENTAÇÃO DO CONHECIMENTO HISTÓRICO (REYNOLDS ET. AL, 2005).	29
FIGURA 11: ESQUEMA DA INTEGRAÇÃO DOS CONHECIMENTOS NA FUNÇÃO DE INFLUÊNCIA (ADAPTADO DE REYNOLDS, 2003A).	35
FIGURA 12: INTERAÇÃO ENTRE OS TIPOS DE CONHECIMENTOS (ADAPTADO DE REYNOLDS, 2003A).....	36
FIGURA 13: GRÁFICO DA MÉDIA INICIAL DE CUSTO DO MELHOR INDIVÍDUO – CASO 3 GERADORES.....	44
FIGURA 14: GRÁFICO DA MÉDIA INICIAL DE CUSTO DO MELHOR INDIVÍDUO – CASO 3 GERADORES (RODRIGUES, 2007).....	44
FIGURA 15: GRÁFICO DOS MELHORES CUSTOS DO MELHOR INDIVÍDUO – CASO 3 GERADORES.	45
FIGURA 16: GRÁFICO DOS MELHORES CUSTOS DO MELHOR INDIVÍDUO – CASO 3 GERADORES (RODRIGUES, 2007).	45
FIGURA 17: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS OPERADORES DE MUTAÇÃO E CRUZAMENTO – CASO 3 GERADORES.	46
FIGURA 18: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS OPERADORES DE MUTAÇÃO E CRUZAMENTO – CASO 3 GERADORES (RODRIGUES, 2007).	46
FIGURA 19: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS CONHECIMENTOS – CASO 3 GERADORES.	47
FIGURA 20: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS CONHECIMENTOS – CASO 3 GERADORES (RODRIGUES, 2007).	47
FIGURA 21: GRÁFICO DA MÉDIA INICIAL DE CUSTO DO MELHOR INDIVÍDUO – CASO 13 GERADORES.....	49
FIGURA 22: GRÁFICO DA MÉDIA INICIAL DE CUSTO DO MELHOR INDIVÍDUO – CASO 13 GERADORES (RODRIGUES, 2007).....	50
FIGURA 23: GRÁFICO DOS MELHORES CUSTOS DO MELHOR INDIVÍDUO – CASO 13 GERADORES.....	50
FIGURA 24: GRÁFICO DOS MELHORES CUSTOS DO MELHOR INDIVÍDUO – CASO 13 GERADORES (RODRIGUES, 2007).	51
FIGURA 25: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS OPERADORES DE MUTAÇÃO E CRUZAMENTO – CASO 13 GERADORES.	51
FIGURA 26: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS OPERADORES DE MUTAÇÃO E CRUZAMENTO – CASO 13 GERADORES (RODRIGUES, 2007).	52
FIGURA 27: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS CONHECIMENTOS – CASO 13 GERADORES.....	52
FIGURA 28: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS CONHECIMENTOS – CASO 13 GERADORES (RODRIGUES, 2007).	53
FIGURA 29: GRÁFICO DA MÉDIA DE CUSTO – ALFA 0.0 – CASO 6 GERADORES.	57
FIGURA 30: GRÁFICO DA MÉDIA DE EMISSÕES – ALFA 0.0 – CASO 6 GERADORES.	57
FIGURA 31: GRÁFICO DA MÉDIA DE CUSTO – ALFA 0.0 – CASO 6 GERADORES (RODRIGUES, 2007).	57
FIGURA 32: GRÁFICO DA MÉDIA DE EMISSÕES – ALFA 0.0 – CASO 6 GERADORES (RODRIGUES, 2007).....	58
FIGURA 33: GRÁFICO DOS MELHORES CUSTO – ALFA 0.0 – CASO 6 GERADORES.	58
FIGURA 34: GRÁFICO DAS MELHORES EMISSÕES – ALFA 0.0 – CASO 6 GERADORES.	59
FIGURA 35: GRÁFICO DOS MELHORES CUSTO – ALFA 0.0 – CASO 6 GERADORES (RODRIGUES, 2007).	59
FIGURA 36: GRÁFICO DAS MELHORES EMISSÕES – ALFA 0.0 – CASO 6 GERADORES (RODRIGUES, 2007).....	59
FIGURA 37: GRÁFICO DA EVOLUÇÃO DO OPERADORES DE MUTAÇÃO E CRUZAMENTO – ALFA 0.0 - CASO 6 GERADORES.	60
FIGURA 38: GRÁFICO DA EVOLUÇÃO DO OPERADORES DE MUTAÇÃO E CRUZAMENTO – ALFA 0.0 - CASO 6 GERADORES (RODRIGUES, 2007).	60
FIGURA 39: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS CONHECIMENTOS – ALFA 0.0 - CASO 6 GERADORES.	61
FIGURA 40: GRÁFICO DO INÍCIO DA EVOLUÇÃO DOS CONHECIMENTOS – ALFA 0.0 - CASO 6 GERADORES (RODRIGUES, 2007).	61
FIGURA 41: APROXIMAÇÃO DA FRONTEIRA DE PARETO OBTIDA PELO AC ESTENDIDO.....	62
FIGURA 42: APROXIMAÇÃO DA FRONTEIRA DE PARETO OBTIDA PELO AC.	62
FIGURA 43: APROXIMAÇÃO DA FRONTEIRA DE PARETO OBTIDA PELO AGCOE.	62

LISTA DE TABELAS

TABELA 1: CARACTERÍSTICAS DO SISTEMA – CASO 3 GERADORES	42
TABELA 2: ALOCAÇÃO DAS POTÊNCIAS – CASO 3 GERADORES.....	43
TABELA 3: MELHOR VALOR DE CUSTO OBTIDO – CASO 3 GERADORES.....	43
TABELA 4: CARACTERÍSTICAS DO SISTEMA – CASO 13 GERADORES.....	46
TABELA 5: ALOCAÇÃO DAS POTÊNCIAS – CASO 13 GERADORES.....	47
TABELA 6: MELHOR VALOR DE CUSTO – CASO 13 GERADORES	47
TABELA 7: CARACTERÍSTICAS DO SISTEMA – CASO 6 GERADORES.....	50
TABELA 8: LIMITES OPERACIONAIS – CASO 6 GERADORES	50
TABELA 9: ALOCAÇÃO DAS POTÊNCIAS PELO AGHCOE – CASO 6 GERADORES – DEA.....	51
TABELA 10: ALOCAÇÃO DAS POTÊNCIAS PELO AC – CASO 6 GERADORES – DEA.....	51
TABELA 11: ALOCAÇÃO DAS POTÊNCIAS PELO AC ESTENDIDO.....	51
TABELA 12: CUSTO E EMISSÃO DO AGHCOE, AC E AC ESTENDIDO – CASO 6 GERADORES - DEA.....	52
TABELA 13: VALOR DA FUNÇÃO OBJETIVO AGHCOE, AC E AC ESTENDIDO – CASO 6 GERADORES – DEA.....	52

LISTA DE ABREVIATURAS E SIGLAS

AC	Algoritmo Cultural
AE	Algoritmo Evolutivo
AG	Algoritmo Genético
AG + E + P	Algoritmo Genético com Elitismo e Penalidade
AGHCOE	Algoritmo Genético Híbrido Co-Evolutivo
CE	Computação Evolutiva
DE	Despacho Econômico
DA	Despacho Ambiental
GA + GE + AT	Algoritmo Genético com Geração Elitista à Parte e Atavismo

1 INTRODUÇÃO

Os problemas de otimização combinatória, comumente vistos em engenharias e tecnologias, ocorrem em diversas áreas, tais como: projetos de sistemas de distribuição de energia elétrica, posicionamento de satélites, projetos de computadores e de chips VLSI, roteamento ou escalonamento de veículos, alocação de trabalhadores ou máquinas a tarefas, empacotamento de caixas em containers, corte de barras e placas e etc.

Muitos desses problemas podem ser modelados como problemas de maximizar ou minimizar uma função objetivo cujas variáveis devem obedecer a certas restrições ou não. O processo de encontrar soluções ótimas, ou até mesmo aproximadas, para esses tipos de problemas nem sempre é trivial.

O Despacho de energia elétrica é um exemplo clássico de aplicação de otimização para resolução de problemas de programação não-linear, que consiste em encontrar o valor ótimo de energia que deve ser produzida em cada unidade geradora para que se consiga operar com um custo e/ou emissão de poluentes minimizados.

Atualmente, os métodos heurísticos, aqueles que permitem a obtenção de soluções viáveis, não necessariamente ótimas, mas com uma boa aproximação para problemas reais e com maior rapidez, têm sido empregado na resolução de problemas de otimização.

Os Algoritmos Culturais constituem uma metodologia heurística recente que se embasa na suposição de que o conhecimento do domínio pode ser extraído durante o processo evolucionário. Sua evolução genética é orientada pela evolução fenotípica de determinados indivíduos.

Esse trabalho propõe uma extensão de um Algoritmo Genético Aculturado para resolver problemas de Despacho

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo geral desse trabalho é a extensão de um Algoritmo Cultural, acrescentando a ele conhecimento histórico, para resolução eficiente de problemas de Despacho em sistemas de geração de energia elétrica.

1.1.2 Objetivos Específicos

Os objetivos específicos são:

- a) Estudar os problemas de despacho em geração de energia e correlacioná-los com problemas do processo produtivo.
- b) Estudar as metodologias baseadas em algoritmos genéticos e algoritmos culturais.
- c) Contribuir para o desenvolvimento de pesquisas na área de programação não-linear.
- d) Contribuir para o aprimoramento da resolução de problemas de Despacho.

1.2 Organização do Trabalho

Esta monografia encontra-se estruturada em quatro capítulos. O Capítulo 2 apresenta os assuntos que servirão como base para a metodologia a ser proposta. O tópico 2.1 introduz o conceito de otimização e o subtópico 2.1.1 aborda os problemas de otimização em Engenharia de Produção e caracterizam alguns desses problemas. No tópico 2.2 são apresentadas as perspectivas do problema de despacho. O subtópico 2.2.1 enfoca o problema do Despacho Econômico através da conceituação e modelagem matemática. Já o subtópico 2.2.2 aborda os conceitos e formulação matemática do Despacho Ambiental.

Os principais conceitos de algoritmos genéticos são apresentados no tópico 2.3. O subtópico 2.3.1 aborda a codificação dos indivíduos. A geração da população inicial é apresentada no subtópico 2.3.2. A função de aptidão é conceituada no subtópico 2.3.3, os operadores genéticos no subtópico 2.3.4, a seleção de indivíduos no subtópico 2.3.5, os parâmetros do algoritmo no subtópico 2.3.6 e os critérios de parada no subtópico 2.3.7.

A seção 2.4 introduz os conceitos de algoritmos culturais, apresentando suas características no subtópico 2.4.1, suas aplicações no subtópico 2.4.2 e suas categorias de conhecimento no subtópico 2.4.3.

No Capítulo 3 é apresentada a metodologia utilizada para extensão do Algoritmo Cultural proposto por Rodrigues (2007). O tópico 3.1 aborda a definição do espaço populacional. O espaço de crença é apresentado no tópico 3.2, as categorias de conhecimento no tópico 3.3 e a adaptação dos parâmetros no tópico 3.4.

O Capítulo 4 apresenta as simulações computacionais e discussão dos resultados alcançados abordando no tópico 4.1 o Despacho Econômico e no tópico 4.2 o Despacho Econômico/Ambiental. Por fim, é apresentada a conclusão, onde são tecidas considerações finais sobre o algoritmo estendido e trabalhos futuros.

2 REVISÃO DA LITERATURA

2.1 Otimização

Em termos técnicos, a otimização é o processo de encontrar a melhor solução dentre um conjunto de soluções para um problema, e ou ainda, é a técnica utilizada para minimizar (ou maximizar) uma função sujeita a restrições em suas variáveis.

A otimização é aplicada nas mais diversas áreas, engenharia, economia, química, biologia, agronomia, entre outras. Seu problema geral consiste na composição de uma função objetivo que relacione diferentes variáveis do problema considerando sujeita, ou não, a restrições impostas.

São empregadas técnicas de otimização quando não existe uma solução simples e diretamente calculável para o problema. Tal fato, geralmente, ocorre quando o problema tem uma estrutura complexa ou número de possíveis soluções é elevado. Em tais situações, é provável que não exista nenhum método direto de solução, de modo que as técnicas de otimização podem ser aplicadas na busca pela melhor solução para o problema em questão.

As soluções para um problema de otimização podem ser divididas em: ótimo local e global. Uma solução é dita um ótimo local se ela é viável e se em sua vizinhança não possui soluções que sejam ao mesmo tempo viáveis e apresentem melhores valores da função objetivo. Uma solução é denominada ótimo global se ela é viável e não há nenhuma outra solução viável com melhor valor da função objetivo.

Em algumas aplicações encontrar o ótimo global é praticamente impossível, no entanto, um ótimo local pode ser uma solução eficiente. Em casos em que o tempo é um fator limitante, encontrar um ótimo local rapidamente é mais desejável do que encontrar demoradamente a melhor solução possível.

A escolha da técnica de otimização a ser empregada depende da estrutura do problema e do grau de confiabilidade das variáveis utilizadas. Em Oliveira (*apud* Belpiede, 2006) é apresentada uma classificação detalhada de alguns métodos para busca de soluções de problemas de otimização mais conhecidos. As técnicas, de forma simplificada, podem ser agrupadas em:

- a) técnicas baseadas em cálculos matemáticos;
- b) técnicas baseadas em programação matemática;
- c) técnicas baseadas em busca aleatória direcionada.

As técnicas de otimização baseadas em cálculo matemático e programação matemática são bastante conhecidas, confiáveis e possuem aplicação nos diversos campos da física, engenharia e outras ciências. No entanto, estas técnicas podem apresentar algumas dificuldades numéricas e problemas de robustez relacionados com a de continuidade das funções a serem otimizadas ou de suas restrições, funções não-convexas, multimodalidade, existência de ruídos nas funções, necessidade de trabalhar com valores discretos para as variáveis, existência de mínimos ou máximos locais, etc (Oliveira *apud* Belpiede 2006).

As técnicas baseadas em busca aleatória direcionada atingiram notável popularidade e propiciaram avanços notórios na área de sistemas inteligentes voltada principalmente a Computação Evolutiva (CE). Esses métodos se baseiam nos princípios da evolução biológica natural.

As técnicas baseadas em busca aleatória direcionada são versáteis na resolução de problemas complexos, tanto de otimização como aprendizado de máquina. Entretanto, apresentam como fator limitante o elevado número de avaliações da função objetivo (Oliveira *apud* Belpiede 2006). Essas técnicas são úteis nas tarefas de otimização global em que os métodos determinísticos podem conduzir às soluções locais. Desse modo, elas são aptas para à resolução de problemas não lineares, descontínuos, discretos, multivariáveis, entre outros (Oliveira *apud* Belpiede 2006).

2.1.1 Problemas de Otimização em Engenharia de Produção

A alta competitividade está fazendo com que vários segmentos visem a utilização da otimização de suas atividades para ganhar mercado. Segundo Coelho(2003) os problemas de otimização de projeto têm sido tratados com heurísticas de tentativa e erro ou através da adoção da simplificação de problemas complexos. Isto tem acarretado uma perda de oportunidade de obtenção de projetos melhores com custos e ciclo de projeto reduzido.

No cenário das indústrias, os problemas de otimização apresentam algumas características peculiares, tais como:

- a) presença de múltiplas medidas de desempenho (ou objetivos) que devem ser otimizados simultaneamente;
- b) complexidade incrementada pela presença de acoplamento entre as variáveis de projeto;
- c) variáveis inteiras e reais co-existentes num mesmo problema;
- d) envolvimento de abordagens qualitativas, como por exemplo, a manufaturabilidade do produto e preferências do projetista;
- e) custo computacional elevado devido a presença de diversas soluções ótimas;
- f) complexidade no desenvolvimento de modelos matemáticos.

Além do exposto acima, a otimização no contexto da Engenharia de Produção é de extrema importância, pois ela oferece uma orientação para a tomada de decisões sobre como usar os recursos disponíveis (pessoas, materiais, ferramentas, equipamentos e tempo) para produzir bens ou serviços da forma mais viável possível, considerando os fatores econômicos e ambientais. Ela apresenta um considerável número de aplicações dentro da Engenharia de Produção, como por exemplo: escalonamento *job-shop*, sequenciamento de tarefas, escalonamento flexível, dimensionamento de lotes, sequenciamento de lote, controle de processos, planejamento de seqüência de montagem, balanceamento de linhas de montagem, planejamento e projeto de produtos, agrupamento de máquinas em células, *layout* de células na planta, layout das máquinas com as células, problema de corte e empacotamento, despacho de energia elétrica, logística, entre outros.

Nas seções seguintes serão caracterizados os problemas de dimensionamento de lotes, corte e empacotamento, alocação de recursos, escalonamento *job-shop* e despacho de energia elétrica.

2.1.1.1 Dimensionamento de lotes

O problema de dimensionamento de lotes (*lot-sizing*) consiste em determinar a quantidade de itens a ser produzida em várias ou uma máquina, em cada período ao longo de um horizonte de tempo finito, de modo a atender uma determinada demanda, podendo estar sujeito a algumas restrições, como por exemplo, limitação da capacidade de produção, tendo como função objetivo minimizar os custos. O dimensionamento de lotes pode ser dividido em:

- a) Multiestágio: quando os itens a serem produzidos são dependentes, isto é, a produção de determinado item depende da produção de outro item, que é chamado item componente;
- b) Monoestágio: quando os itens a serem produzidos são independentes, ou seja, nenhum item depende da produção de outro item.

2.1.1.2 Problema de corte e empacotamento

Os problemas de empacotamento são aqueles que requerem que certos objetos (itens) sejam empacotados em outros de tamanhos maiores (recipientes). Em algumas aplicações, ao invés em vez de empacotar, o objetivo é cortar.

Embora os problemas de empacotamento e corte sejam equivalentes, as diferenças ocorrem quando consideramos as diferentes restrições que ocorrem em cada caso. Esses problemas são amplamente estudados devido ao grande interesse prático e teórico.

Segundo Arenales *et. al* (2004) problemas de corte e empacotamento têm uma estrutura idêntica e podem ser descritos de forma similar, pois, cortar unidades maiores em unidades menores ou empacotar unidades menores dentro de unidades maiores são problemas idênticos, considerando que um item cortado de uma certa posição pode ser pensado como alocado àquela posição.

2.1.1.3 Alocação de recursos

O problema de alocação de recursos refere-se à atribuição e distribuição de recursos entre as diversas atividades que devem ser realizadas. O número de recursos é limitado e, na maioria das vezes, não é suficiente para atender a todas as tarefas da forma desejada. Com isso, é necessário encontrar a melhor distribuição dos recursos entre as diversas tarefas, de modo a atingir um valor ótimo do objetivo estabelecido.

Segundo Andrade (2004) a alocação de recursos é caracterizada por:

- a) Existência de um objetivo que pode ser explicitado em termos das variáveis de decisão do problema;
- b) Existência de restrições, tanto em relação à quantidade disponível quanto a forma de emprego.

2.1.1.4 Escalonamento *job-shop*

Os problemas de *job shop* são os mais gerais problemas de *scheduling* de produção em qualquer classificação e também os de mais difícil solução. Aqui não existem restrições nos passos de processamento de uma tarefa e roteiros alternativos para uma tarefa podem ser permitidos. Adicionalmente, não existem restrições aos requisitos associados com cada tarefa, assim, uma tarefa pode requerer processamento em qualquer subconjunto de processadores em qualquer ordem concebível (GRAVES, 1981).

2.1.1.5 Despacho de Energia Elétrica

O problema de despacho de energia elétrica subdivide-se em duas abordagens, uma que enfoca o aspecto econômico e outra que enfoca o aspecto ambiental. Essas abordagens podem ser combinadas gerando assim um novo problema que considera os dois enfoques ao mesmo tempo.

O Despacho Econômico (DE), é um dos problemas de otimização bastante estudado, que procura alocar otimamente uma demanda entre as unidades geradoras de um sistema de geração termoelétrica. Seu objetivo consiste em minimizar o custo de produção da energia elétrica (RODRIGUES, 2007).

A função do Despacho Ambiental (DA) objetiva minimizar a emissão de poluentes no processo de geração de energia em termelétricas.

O problema de despacho pode ser visto como um conjunto de problemas que congrega como subproblemas a alocação de recursos e o sequenciamento de tarefas. O Despacho será o problema alvo dessa monografia.

O próximo capítulo apresentará as abordagens do problema de despacho e a formulação matemática do problema.

2.2 Perspectivas do Problema de Despacho de Energia Elétrica

O problema de Despacho pode ser analisado sob duas perspectivas, econômico e ambiental. Além disso, tem-se uma abordagem que objetiva resolver o problema considerando as duas abordagens simultaneamente.

As seções seguintes apresentarão conceitos básicos e definições sobre Despacho Econômico (DE), Despacho Ambiental (DA) e Despacho Econômico/Ambiental (DEA).

2.2.1 Despacho Econômico

A função básica dos sistemas elétricos de potência é suprir os consumidores com energia elétrica da forma mais econômica e confiável possível (TAKAHASHI, 2004). A operação econômica desse sistema é um tema interessante para as empresas de geração de energia elétrica devido ao crescimento do custo dos combustíveis fósseis não-renováveis.

O problema de Despacho Econômico consiste em programar a carga das unidades geradoras térmicas que se encontram sincronizadas ao sistema de modo a satisfazer a demanda a um custo mínimo (HARNISCH *et al.*, 2000). A otimização da distribuição da produção entre os geradores e a utilização eficiente dos recursos são utilizados para atingir o objetivo do DE que é a minimização do custo de produção de energia elétrica.

Para o DE, satisfazer a função objetivo não é o suficiente, é necessário respeitar as restrições do problema, que no caso são as condições de operação do sistema, tais como: as características operacionais de cada gerador e o balanço de energia. A potência de saída de cada unidade geradora de energia é o resultado da satisfação dos objetivos e o custo total da geração é dado pelo somatório de cada uma das unidades.

O tópico a seguir apresentará o problema em termos matemáticos.

2.2.1.1 Modelagem do Despacho Econômico

O modelo clássico para o DE é formulado da seguinte forma (SAMEDI, 2004):

$$\min F_e \quad (1)$$

Sujeito as seguintes restrições:

$$\begin{aligned} \sum P_i &= P_D \\ P_i^{\min} &\leq P_i \leq P_i^{\max} \end{aligned} \quad (2)$$

Em que:

- a) F_e : função custo total de geração do Despacho Econômico

- b) P_i : Potência de saída do i-ésimo gerador.
- c) P_i^{min} : Potência mínima de cada unidade geradora.
- d) P_i^{max} : Potência máxima de cada unidade geradora.
- e) P_D : Valor da demanda.

A Equação 3 aplicada a cada unidade geradora representa o custo total da geração termoelétrica.

$$Fe = \sum_{i=1}^n Fe_i P_i = \sum a_i P_{Gi}^2 + b_i P_{Gi} + c_i \quad (3)$$

Em que:

- a) F_{ei} : custo de cada unidade geradora.
- b) P_i : potência de saída do i-ésimo gerador.
- c) a_i, b_i e c_i : coeficientes característicos da função custo.

2.2.2 Despacho Ambiental

O Despacho Ambiental (DA) consiste em encontrar os níveis de concentração resultantes da relação entre a quantidade de cada poluente e a saída de potência dos geradores que minimizem a emissão de poluentes, satisfazendo as mesmas restrições do DE.

O tópico a seguir apresenta a modelagem do problema.

2.2.2.1 Modelagem do Despacho Ambiental

A modelagem matemática do problema é dada por (SAMMED, 2004):

$$\min Fa \quad (4)$$

Sujeito às restrições:

$$\begin{aligned} \sum P_i &= P_D \\ P_i^{min} &\leq P_i \leq P_i^{max} \end{aligned} \quad (5)$$

Em que:

- a) F_a : função emissão total de geração do Despacho Ambiental
- b) P_i : Potência de saída do i -ésimo gerador.
- c) P_i^{min} : Potência mínima de cada unidade geradora.
- d) P_i^{max} : Potência máxima de cada unidade geradora.
- e) P_D : Valor da demanda.

A função objetivo é representada pela equação 6, que é uma função polinomial quadrática (SAMED, 2004).

$$Fa_i(P_i) = A_i P_i^2 + B_i P_i + C_i \quad (6)$$

Em que:

- a) F_a : custo de cada unidade geradora.
- b) P_i : potência de saída do i -ésimo gerador.
- c) a_i, b_i e c_i : coeficientes característicos da função custo.

A Equação 7 representa o total de emissões:

$$Fa = \sum_{i=1}^n Fa(P_i) \quad (7)$$

2.3 Algoritmos Genéticos

Algoritmos Genéticos (AGs) são algoritmos estocásticos de busca inspirados nos mecanismos de evolução do seres vivos (MICHALEWICZ, 1999). Eles possuem uma analogia direta com a teoria do naturalista e fisiologista inglês Charles Darwin (1859), segundo a qual quanto melhor um indivíduo se adaptar ao seu meio ambiente, maior será sua chance de sobreviver e gerar descendentes.

Os algoritmos genéticos baseiam-se em uma abordagem probabilística, e, embora não garantam o ponto ótimo global, tendem a alcançá-lo desviando-se das soluções ótimas locais.

Além disso, devido à natureza estocástica, o seu desempenho deve ser calculado considerando-se um número médio de simulações ao invés de uma única rodada.

Segundo Michalewicz (1999), um algoritmo genético apresenta cinco aspectos fundamentais quando utilizado para resolver um problema:

- a) representação genética das soluções candidatas ou potenciais, ou seja, processo de codificação;
- b) uma forma de gerar uma população inicial de soluções candidatas ou potenciais;
- c) uma função aptidão que avalie as soluções e classifique-as de acordo com sua adaptação ao meio ;
- d) operadores genéticos para a reprodução de novos indivíduos;
- e) identificar os valores para os vários parâmetros do algoritmo genético, tais como: tamanho da população, critérios de parada do algoritmo, método de seleção, taxa de mutação, entre outros.

A manipulação concatenada dos aspectos acima citados tornou viável a codificação e utilização de algoritmos genéticos de uma forma robusta e independente, capaz de ser utilizada em uma infinidade de problemas de forma eficiente. De acordo com Falcone (2004) os algoritmos genéticos são aplicações promissoras em problemas com um número elevado de variáveis, não-lineares e com natureza discreta. Eles apresentam, também, uma boa capacidade de solução de problemas com múltiplos objetivos.

O pseudocódigo básico de um AG é :

Algoritmo 1: Pseudocódigo do algoritmo genético

Início

 $t \leftarrow 0$

Gerar população inicial

Avaliar os indivíduos da população

Enquanto não atender critério de parada (tempo, gerações, função objetivo)

Início $t \leftarrow t + 1$

Selecionar uma subpopulação de indivíduos e formar o conjunto de pais

Recombinar os “genes” dos pais

Realizar mutações

Avaliar os indivíduos

Renovar população

Fim Enquanto**Fim**

As seções seguintes apresentam uma descrição detalhada dos elementos: codificação, geração a população inicial, função de aptidão, seleção de indivíduo, parâmetros e critérios de parada.

2.3.1 Codificação dos indivíduos

A codificação ou representação dos parâmetros relativos ao problema a ser analisado é o ponto de partida para a aplicação de AG's a um problema qualquer (busca ou otimização).

A codificação transforma as variáveis do problema em um cromossomo, para que os AG's possam atuar adequadamente sobre elas. O cromossomo, conjunto ordenado de genes que caracteriza um único indivíduo, é uma estrutura de dados, geralmente vetores ou cadeia de valores binários, reais ou combinação de ambas. É uma possível solução para o problema a ser otimizado (SILVA, 2005).

De modo geral, o cromossomo representa o conjunto de parâmetros da função objetivo cuja resposta será otimizada. O conjunto de todas as configurações que o cromossomo pode assumir forma o seu espaço de busca. Se o cromossomo representa n parâmetros de uma função, então o espaço de busca é um espaço de n dimensões.

A maioria das representações são genotípicas. O genótipo é o conjunto de genes que define a constituição genética de um indivíduo e sobre estes genes é que serão aplicados os operadores genéticos. Essas representações utilizam vetores de tamanho finito. A representação em níveis

de abstração mais elevados tem sido investigada por Oliveira (2001 *apud* SILVA, 2005) e por serem mais fenotípicas, facilitariam seu uso em determinados ambiente. Nesse caso, precisariam ser criados os operadores específicos para utilizar essa representação.

Os tipos de representação genotípicas utilizados com mais frequência são: codificação binária, codificação Gray e codificação real. A seguir tais representações serão abordadas detalhadamente.

2.3.1.1 Codificação binária

A codificação binária é a clássica e tem sido utilizada desde o trabalho precursor de Holland. Além disso, ela ainda é a codificação mais usada, por ser de fácil utilização e manipulação, e simples de analisar teoricamente.

Nesse tipo de codificação são utilizados números binários, ou seja, apenas conjuntos de 0 e 1 para representar as variáveis. Cada parâmetro é representado por um conjunto de bits (genes). Cada variável pode ser representada por um número distinto de bits, conforme a precisão requerida.

Apesar da simplicidade, existem alguns problemas em trabalhar com a codificação binária. Se um problema tem parâmetros contínuos e o usuário desejar trabalhar com maior precisão, provavelmente utilizará longos cromossomos para representar soluções, o que requer uma grande quantidade de memória.

Silva (2005) destaca ainda o aspecto da não-uniformidade dos operadores. Por exemplo, se o valor real de um gene for codificado por um vetor binário, a mutação nos primeiros valores binários do gene afetará mais a aptidão do cromossomo que a mutação nos seus últimos valores.

2.3.1.2 Codificação Gray

Do mesmo modo que a codificação binária, a codificação *Gray* utiliza apenas cadeias de 0 e 1 para representar os parâmetros. A diferença é que o código *Gray* apresenta a propriedade de que todos os números inteiros adjacentes possuem apenas um bit de diferença.

Mognon (2006) destaca que o problema desse tipo de codificação é que duas variáveis com apenas um bit de diferença podem não ser inteiros adjacentes. De qualquer modo, a

codificação *Gray* ajuda na convergência final dos algoritmos genéticos e favorece a precisão da solução. Entretanto, ela pode levar a um ótimo local.

2.3.1.3 Codificação real

A codificação real trabalha diretamente com números reais, o que é útil quando os parâmetros a serem otimizados são variáveis contínuas (RAHMAT-SAMII e MICHIELSSEN *apud* MOGNON, 2006). Em termos computacionais, são utilizados números de ponto-flutuante para representar o valor das variáveis e executar as operações genéticas de cruzamento e mutação.

Michalewicz (1999) destaca que a codificação real apresenta maior precisão e capacidade de representação de domínios de um problema. Experimentos indicam que sua utilização possibilita maior: velocidade de processamento, consistência dos resultados entre rodadas e precisão quando comparada à representação binária.

2.3.2 Geração da população inicial

A geração da população inicial requer algumas ponderações, pois a representação do espaço de busca deve ser a mais sensível possível. Silva (2005) identifica os seguintes tipos de inicialização:

- a) Inicialização Aleatória: os indivíduos da população são gerados de forma aleatória.
- b) Inicialização Determinística: os indivíduos da população são gerados segundo uma determinada heurística.
- c) Inicialização Aleatória com Nicho: os indivíduos da população são gerados de forma que possam ser divididos em espécies, ou seja, indivíduos com características semelhantes.

Segundo Silva (2005) e Falcone (2004), na maior parte das aplicações a população inicial é gerada de forma aleatória ou através de alguma heurística.

O tamanho da população relaciona-se diretamente com o desempenho do algoritmo. Uma população pequena terá o problema de perda de diversidade, ou seja, o espaço de busca seria muito pequeno para ser avaliado, diminuindo assim as possibilidades de se atingir o ótimo

global. Conseqüentemente, a convergência seria prematura, e o valor encontrado seria um ponto ótimo local. Em populações grandes a probabilidade de convergência seria maior, pois a probabilidade da solução desejada ser constatada entre os elementos aumenta. No entanto, o tempo de processamento também aumenta.

2.3.3 Função de aptidão

A função de aptidão ou *fitness* representa uma medida que avalia a capacidade e potencialidade dos indivíduos da população durante o processo evolutivo. Esta medida servirá como base para classificação dessas soluções, indicando a sua qualidade, ou seja, as suas chances de sobrevivência e conseqüente reprodução.

A escolha da função de aptidão está diretamente relacionada com o domínio do problema. Segundo Bastos (2004), genericamente a função de aptidão para um problema de otimização pode ser definida como:

$$F(x) = f(x) + penal(x) \quad (8)$$

Onde $f(x)$ é a função objetivo e $penal(x)$ é denominada função de penalização. Em geral, a função objetivo é relacionada direta ou indiretamente a um critério econômico, e a função de penalização está associada às diferentes restrições do problema. Se o problema não apresentar restrições em sua formulação então a função penalização é desconsiderada e a função de aptidão é a própria função objetivo.

Bastos (2004) ressalta que a função de aptidão é a parte da programação que demanda maior custo computacional, uma vez que ela avalia todos os indivíduos de cada geração. Haupt (*apud* BASTOS, 2004) apresenta alguns cuidados que devem ser tomados para reduzir o custo computacional: não avaliar o mesmo indivíduo mais de uma vez; evitar gerar cromossomos idênticos na população inicial; verificar se os pais são distintos aos filhos; manter a população com todos os cromossomos distintos entre si; e, criar uma memória para os algoritmos genéticos a fim de verificar e um determinado indivíduo já não foi gerado anteriormente.

2.3.4 Operadores genéticos

Um algoritmo de otimização global deve ser capaz de explorar pontos inteiramente novos dentro do espaço de busca, bem como intensificar a busca nas regiões consideradas

promissoras. Esse mecanismo de diversificação (*exploration*) e intensificação (*explotation*) é alcançado nos algoritmos genéticos pela correta aplicação dos operadores genéticos.

O objetivo principal dos operadores genéticos é transformar a população através de sucessivas gerações, para obter um resultado satisfatório no final do processo. Deste modo, eles são extremamente necessários para que a população se diversifique e mantenha as características de adaptação adquiridas pelas gerações anteriores.

Os operadores genéticos mais utilizados, cruzamento e mutação, serão descritos a seguir.

2.3.4.1 Cruzamento

A operação de cruzamento (codificação binária) ou recombinação (codificação real) é o processo em que os indivíduos recombinaem seu material genético para gerar novos indivíduos, provocando assim a convergência da população ao longo das gerações.

Existem diversos tipos de cruzamento. Falcone (2004) aborda os seguintes:

- a) Cruzamento com um ponto de corte: é o operador mais clássico. Consiste em escolher aleatoriamente um ponto entre os limites dos cromossomos selecionados como progenitores e realizar a permutação do material genético entre eles. A Figura 1 ilustra o cruzamento com um ponto de corte.




Figura 1: Representação do cruzamento com um ponto de corte.

- b) Cruzamento com 2 pontos de corte: análogo ao primeiro, a diferença é que serão escolhidos dois pontos no mesmo intervalo ao invés de um. A Figura 2 apresenta a representação do cruzamento com dois pontos de corte.




Figura 2: Representação do cruzamento com dois pontos de corte.

- c) Cruzamento com n pontos: é uma generalização do modelo de um ponto de corte, no qual são determinados aleatoriamente n pontos, do mesmo intervalo, para troca do material genético. A representação do cruzamento com n pontos de corte, em que $n=4$, é ilustrada na Figura 3.




Figura 3: Representação do cruzamento com n ($n=4$) pontos de corte.

- d) Cruzamento uniforme: nesse processo é gerada uma máscara de bits aleatórios que servirão de base para determinar como será realizada a troca do material genético. A codificação dos filhos é obtida pela permuta ou não dos genes dos pais. Se a máscara contiver o bit “1” em determinada posição então ocorrerá a permuta do bit, caso contrário nada acontecerá.
- e) Cruzamento por variável: o número de pontos de corte será determinado por variável. Se consideradas 4 variáveis tem-se 4 pontos de corte.
- f) Cruzamento entre vários indivíduos: seleciona-se o indivíduo base e depois, para cada variável, determina-se aleatoriamente um parceiro e um ponto de corte.

2.3.4.2 Mutação

A mutação é o operador genético que introduz variabilidade dentro da população e consiste em alterar arbitrariamente o valor de um ou mais genes de um indivíduo.

De acordo com Mognon (2006) a mutação é um operador genético muito simples de ser realizado. Em casos com codificação binária, basta escolher um bit no cromossomo e inverter o seu valor.




Figura 4: Representação da mutação.

Nas situações com codificação real a mutação pode ser realizada através de uma perturbação aleatória em genes escolhidos aleatoriamente.

2.3.5 Seleção de indivíduos

A seleção introduz a influência da função de aptidão no procedimento de otimização do algoritmo genético. Do mesmo modo que ocorre no processo de seleção natural, os indivíduos mais qualificados, de acordo com a função objetivo, apresentam maior probabilidade de serem escolhidos. Entretanto, a seleção não deve se limitar à escolha do melhor indivíduo, pois há a probabilidade deste não estar perto da solução ótima global. Sendo assim, é necessário manter alguma chance dos indivíduos com aptidão relativamente baixa participarem do processo de reprodução. Existem diversas estratégias de seleção, algumas delas são descritas a seguir.

- a) Seleção por roda roleta: é o método mais simples e mais utilizado. Consiste em colocar todos os indivíduos numa roleta, onde a posição de cada indivíduo é proporcional a sua aptidão. A roleta é girada n vezes até que se obtenha o número de indivíduos necessários.
- b) Seleção por torneio: escolhem-se aleatoriamente n indivíduos da população, com a mesma probabilidade. O indivíduo com maior aptidão dentre os n indivíduos é selecionado para a população intermediária. O processo é repetido até que a população intermediária seja preenchida.
- c) Amostragem estocástica: é uma variação do método roda roleta em que, ao invés de uma única agulha, n agulhas igualmente espaçadas são utilizadas, onde n é o

número de indivíduos a serem selecionados. Desse modo, ao invés de n vezes, a roleta é girada apenas uma vez.

- d) Seleção por ranking: ordenam-se os indivíduos de acordo com a aptidão e utilizam-se as posições dos indivíduos após tal ordenação para definir os valores de probabilidade seleção, usando mapeamentos lineares ou não-lineares para estabelecer tal probabilidade.
- e) Seleção por diversidade: a partir do melhor indivíduo são selecionados os mais diversos indivíduos da população.
- f) Seleção *steady-state*: a população original é mantida, com exceção de alguns poucos indivíduos menos adaptados.
- g) Seleção aleatória salvacionista: seleciona-se o melhor indivíduo e os outros aleatoriamente.
- h) Seleção elitista: seleciona-se P% dos melhores indivíduos e os outros aleatoriamente ou por meio de roda roleta.

2.3.6 Parâmetros do algoritmo genético

A definição dos parâmetros a serem utilizados em um algoritmo genético influencia fortemente o seu desempenho. Desse modo, é importante analisar como estes parâmetros influem no comportamento dos algoritmos genéticos para que se estabeleçê-los de acordo com as necessidades do problema e dos recursos disponíveis (CANTÚ e GOLDBERG 1999, *apud* SILVA 2005).

Nos algoritmos genéticos existem vários parâmetros que controlam o processo evolutivo, alguns deles são:

- a) Tamanho da População: indica o número de cromossomos em cada população, durante o processo evolutivo.
- b) Taxa de Cruzamento: indica quando irá ocorrer o cruzamento entre indivíduos selecionados na população. Geralmente os valores de taxa de cruzamento são relativamente altos.

- c) Taxa de Mutação: indica a probabilidade em que haverá mutação de cromossomos nas populações ao longo da evolução. A maioria das taxas de mutação assume valores baixos.
- d) Taxa de Substituição: controla a porcentagem da população que será substituída durante a próxima geração.

2.3.7 Critérios de Parada

O critério de parada representa o momento em que se deseja parar a execução do algoritmo. Existem diversos critérios que podem ser empregados em um algoritmo genético. Em geral o processo é interrompido quando (GOLDBERG *apud* RODRIGUES, 2007) (LUCAS *apud* RODRIGUES, 2007) (LACERDA e CARVALHO *apud* RODRIGUES, 2007):

- a) O algoritmo genético alcançar um determinado número de gerações.
- b) For conhecido o valor ótimo da função objetivo e o algoritmo genético atingí-lo.
- c) Houver convergência, ou seja, quando não houver melhora do indivíduo de maior aptidão por um longo número de gerações.

2.4 Algoritmos Culturais

Os métodos de Computação Evolucionária (CE) têm sido utilizados com sucesso na resolução de diversos problemas de busca e otimização devido ao seu bom desempenho em situações em que se tem pouco ou nenhum conhecimento sobre o domínio do problema (FOGEL *apud* REYNOLDS & CHUNG, 1997). Entretanto, pode haver uma melhoria considerável no desempenho do algoritmo evolutivo (AE) quando o conhecimento específico do problema é utilizado no processo de resolução de problemas com o intuito de realizar a identificação de padrões no ambiente (REYNOLDS, 1994; REYNOLDS, 1997). Estes padrões podem ser utilizados para promover os indivíduos desejáveis ou reduzir o número dos indivíduos indesejáveis na população. Além disso, este recurso propicia uma oportunidade para alcançar a solução desejada de forma mais rápida.

No cenário das sociedades humanas a cultura pode ser vista como o veículo para o armazenamento da informação que é globalmente acessível a todos os membros da sociedade

e que pode ser útil no sentido de orientar as atividades de resolução de problemas (REYNOLDS e CHUNG, 1997).

O AC é uma classe de modelo computacional baseado em teorias de sociólogos e arqueólogos, proposto por Robert Reynolds (REYNOLDS, 1994), que se embasa na observação do processo de evolução cultural na natureza humana.

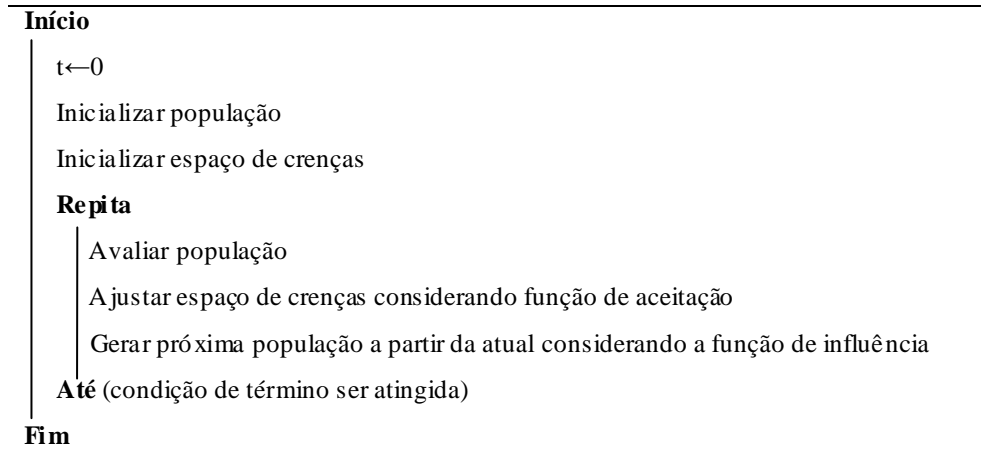
Pesquisadores indicam que a evolução cultural pode ser vista como um processo de herança em dois níveis: o nível micro-evolutivo, que consiste no material genético que os descendentes herdam dos pais, e o nível macro-evolutivo, que é o conhecimento adquirido pelos indivíduos ao longo das gerações, e que uma vez codificado e armazenado, serve para guiar o comportamento dos indivíduos que pertencem a uma população (RENFREW *apud* BECERRA, 2002) (DURHAM *apud* BECERRA, 2002).

O processo de herança dual nos algoritmos culturais tem por objetivo incrementar as taxas de aprendizagem ou convergência, e responder de modo melhor a um maior número de problemas.

Os métodos de CE tradicionais apresentam mecanismos limitados ou implícitos para a representação e armazenamento do conhecimento global de um indivíduo. Os AC's, os quais modelam a evolução do componente cultural de um sistema computacional evolutivo ao longo do tempo, possuem um mecanismo explícito de aquisição, armazenamento e integração da experiência e comportamento na solução do problema de indivíduos e grupos. Um modelo de busca evolutivo pode ser utilizado na modelagem do componente populacional em AC's (REYNOLDS, 1997).

O pseudocódigo básico de um AC é:

Algoritmo 2: Pseudocódigo do algoritmo cultural (Reynolds, 1997).



O algoritmo começa com a inicialização da população e do espaço de crenças, então entra no laço evolutivo até que a condição de término seja satisfeita.

Os algoritmos culturais operam em dois espaços: espaço populacional e espaço de crença (REYNOLDS, 1999). O espaço populacional consiste num conjunto de soluções do problema, e pode ser modelado através de qualquer técnica de Inteligência Artificial que utilize uma população de indivíduos.

O espaço de crença é um repositório em que os indivíduos podem armazenar suas experiências para que os demais indivíduos possam aprender indiretamente. Nos algoritmos culturais, as informações adquiridas por um indivíduo podem ser compartilhadas com toda a população, diferentemente da maioria das técnicas evolucionárias, onde a informação só pode ser compartilhada com os descendentes (BECERRA e COELLO, 2005).

O protocolo de comunicação é o mecanismo responsável por interligar os espaços, populacional e crença. Ele estabelece as regras de comunicação, definindo que tipo de informação deve ser trocada entre os espaços.

A Figura 5 ilustra a estrutura dos AC's.

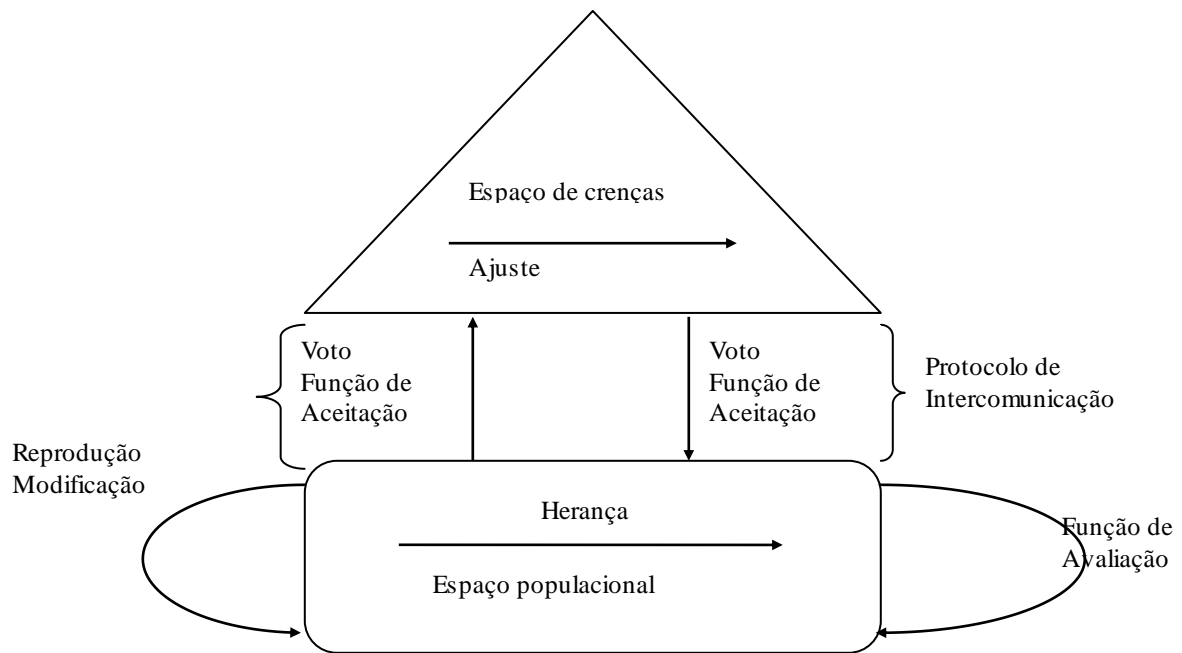


Figura 5 : Estrutura dos algoritmos culturais (Rodrigues, 2007).

A idéia central dos algoritmos culturais é adquirir conhecimento sobre a solução do problema a partir da população em evolução e aplicar este conhecimento para orientar a busca (REYNOLDS, 1994). O conhecimento gerado no espaço populacional é seletivamente aceito ou passado ao espaço de crenças e usado para ajustar as estruturas simbólicas lá existentes. Este conhecimento então pode ser utilizado para influenciar as modificações feitas na próxima geração da população.

2.4.1 Características

Segundo Reynolds (2003) as principais características dos AC's são:

- Mecanismo Dual de Herança: herda característica tanto do nível micro-evolutivo como macro-evolutivo;
- Evolução Orientada por Conhecimento: a população é orientada na direção que, segundo o conhecimento armazenado no espaço de crenças, seja a melhor;
- Suporte a Hierarquia: tanto a população quanto o espaço de conhecimento podem ser organizados de forma hierárquica;

- d) Conhecimento sobre o domínio separado dos indivíduos: o conhecimento adquirido é armazenado no espaço de crenças e compartilhado entre os indivíduos. Desse modo, quando um indivíduo é eliminado da população, o conhecimento adquirido pelo mesmo permanece.
- e) 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.
- f) Diferentes taxas de evolução: a evolução das populações e do conhecimento não precisa ocorrer na mesma taxa.
- g) Estrutura de funcionamento: permite a modelagem de diversas formas de evolução cultural.

2.4.2 Aplicações

De acordo com Reynolds (2003) a aplicação de AC's para resolução de problemas é adequada diante das seguintes situações:

- a) Uma quantidade significativa de conhecimento do domínio. Por exemplo, problemas de otimização com restrição.
- b) Sistemas complexos onde a adaptação pode ocorrer em vários níveis em várias taxas na população e no espaço de crença
- c) O conhecimento se encontra em diferentes formas e necessita ser ponderado em diversas direções.
- d) Sistemas híbridos que necessitam de uma combinação da busca e do conhecimento.
- e) Problemas que requerem população e espaço de crenças múltiplos e interação entre eles.
- f) Os elementos da população e do conhecimento, estruturados de forma hierárquica, podem emergir.

2.4.3 Categorias de Conhecimento

O conhecimento macro-evolutivo pode ser dividido em cinco categorias: normativo, situacional, topográfico, domínio e histórico. As seções seguintes descrevem a estrutura de cada um desses tipos de conhecimentos.

2.4.3.1 Conhecimento Normativo

Esta categoria de conhecimento foi introduzida por Chung (1997). É representado como um conjunto de intervalos de variáveis, e cada um é visto como uma série promissora de soluções boas ou socialmente aceitáveis para um parâmetro (Reynolds et. al, 2005). A Figura 6 representa a estrutura de dados para o conhecimento normativo para n variáveis.




Figura 6 : Representação do Conhecimento Normativo (Reynolds et. al, 2005).

Para cada variável V_i , a estrutura de dados contém o limite superior e inferior para a característica dos indivíduos, l_i e u_i , e os valores limites de aptidão para os indivíduos, sendo L_i o superior e U_i o inferior.

A atualização 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 atualizado e vice-versa (Rodrigues, 2007).

2.4.3.2 Conhecimento Situacional

O Conhecimento Situacional contém um conjunto de exemplos que são úteis para a interpretação da experiência dos indivíduos. A estrutura de dados do conhecimento situacional é representada como uma lista de indivíduos exemplares (Reynolds et. al, 2005). Na Figura 7 é ilustrada a representação do conhecimento situacional.




Figura 7 : Representação (Reynolds et. al, 2005).

O conhecimento situacional é atualizado sempre que é encontrado um indivíduo cuja aptidão seja maior que a do pior indivíduo armazenado.

2.4.3.3 Conhecimento Topográfico

O Conhecimento Topográfico foi proposto com o objetivo de extrair padrões de comportamento do espaço de busca. Esse tipo de conhecimento identifica regiões promissoras dentro do espaço de busca e faz com que novos indivíduos as explorem (Rodrigues, 2007).

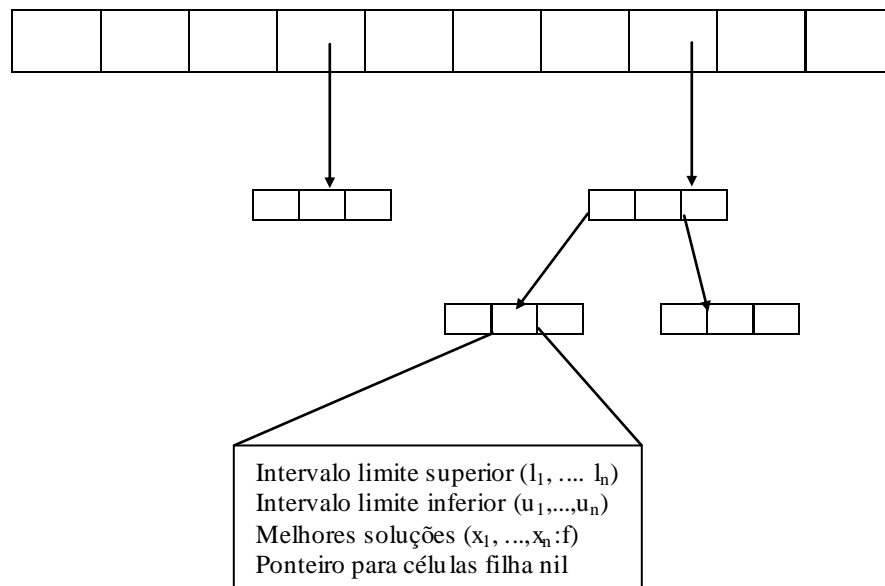


Figura 8 : Representação do Conhecimento Topográfico (Reynolds et. al, 2005).

2.4.3.4 Conhecimento do Domínio

Esta categoria de conhecimento foi introduzida por Reynolds e Saleem (2005) para resolver os problemas dinâmicos de otimização. Ele foi projetado para atuar sobre locais dinâmicos,

especialmente nos termos da predição dos gradientes de inclínio ou declínio. A Figura 9 mostra sua estrutura de dados.

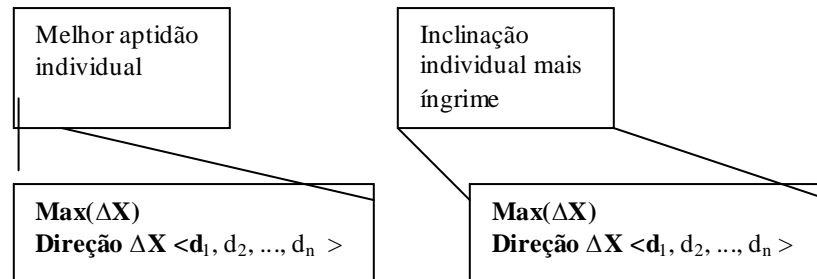


Figura 9 : Representação do Conhecimento do Domínio (Reynolds et. al, 2005).

Segundo Rodrigues (2007) esse tipo de conhecimento é o menos utilizado devido a dificuldade de extração e representação do mesmo.

2.4.3.5 Conhecimento Histórico

O conhecimento histórico foi desenvolvido por Reynolds e Saleem (2005) motivado pela necessidade de desenvolver aprendizado em ambientes dinâmicos. Ele contém informações sobre mudanças de seqüências ambientais em termos dos deslocamentos na distância e no sentido das tendências conhecidas no espaço da busca. Sua origem cognitiva advém de episódios da memória, assim como ocorre nos seres humanos e animais.

Enquanto o Conhecimento de Domínio é focado na interpretação do deslocamento em termos geométricos ou de gradiente, o Conhecimento Histórico provê uma perspectiva global da mudança, onde indivíduos guiados por este conhecimento podem consultar os eventos armazenados para auxiliarem suas decisões quanto a qual direção seguir (Reynolds et. al, 2005).

A Figura 10 ilustra a estrutura de dados utilizada para representar o Conhecimento Histórico. W representa o tamanho da memória para o histórico de eventos de e e (ds_1, \dots, ds_n) e (dr_1, \dots, dr_n) representa a média de mudanças no ambiente na distância e direção para cada um dos parâmetros (Reynolds et. al, 2005). e_1 até e_w são eventos de mudança para cada alteração que a melhor solução do ambiente anterior e a direção a qual cada parâmetro move em direção ao melhor individuo armazenado na lista de histórico.

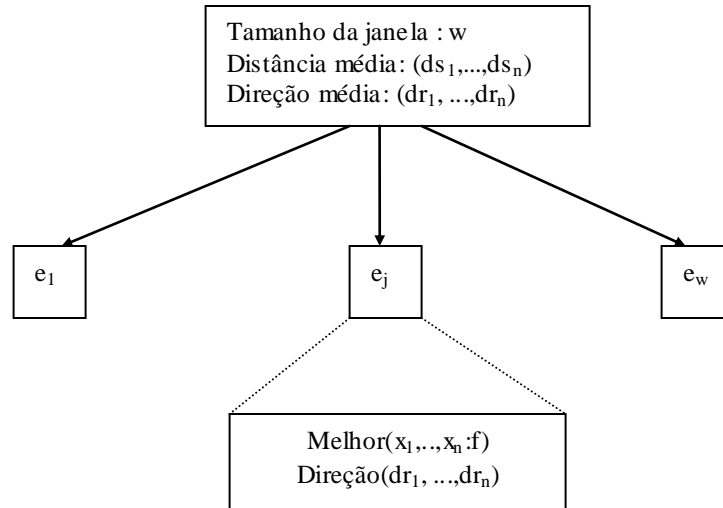


Figura 10 : Representação do Conhecimento Histórico (Reynolds et. al, 2005).

No instante t , em que ocorre uma alteração no ambiente, a melhor solução atual $(x_1, \dots, x_n: f)$ é armazenada juntamente com sua mudança de direção (dr_1, \dots, dr_n) entre os parâmetros do melhor indivíduo do momento e o melhor indivíduo antes da alteração ambiental. A direção dr_j pode assumir os seguintes valores: -1, 0 ou 1. Quando $e_k.dr_j$ igual a 1 indica que o valor do parâmetro j aumenta entre ótimos na atual mudança do ambiente; ou $e_k.dr_j$ é igual a -1 para indicar que o valor do parâmetro j foi diminuído, ou ainda zero, caso contrário (ALMEIDA, 2005).

A Equação 9 apresenta a função que determina a atualização da direção do parâmetro j do k -ésimo evento:

$$e_k.dr_j = \begin{cases} 1 & \text{se } e_k.x_j - e_{k-1}.x_j > 0 \\ -1 & \text{se } e_k.x_j - e_{k-1}.x_j < 0 \\ 0 & \text{caso contrário} \end{cases} \quad (9)$$

A distância média do movimento é determinada, ao ocorrer um novo evento é dada por:

$$ds_j = \frac{\sum_{k=1}^{w-1} e_k \cdot x_j - e_{k+1} \cdot x_j}{w-1} \quad (10)$$

Em que:

- a) x_j : valor do parâmetro j da melhor solução no momento em que ocorre o evento e_k ;
- b) w : número de eventos na lista de histórico

A direção de movimento para o j -ésimo parâmetro pode ser obtida pela Equação 11.

$$dr_j = \begin{cases} 1 & \text{se } \sum_{k=1}^w e_k \cdot dr_j > 0 \\ -1 & \text{se } \sum_{k=1}^w e_k \cdot dr_j < 0 \\ 0 & \text{caso contrário} \end{cases} \quad (11)$$

O conhecimento histórico é atualizado a cada mudança de evento através da atualização da lista histórica e o movimento das médias de cada parâmetro, conforme dado pelas Equações 10 e 11.

3 METODOLOGIA PROPOSTA

Esse trabalho tem por objetivo aprimorar o AC desenvolvido por Rodrigues (2007) para resolver problemas de Despacho Econômico, Despacho Ambiental e Despacho Econômico/Ambiental. A extensão desse algoritmo visa responder às seguintes questões:

- Qual a influência do Conhecimento Histórico no AC proposto por Rodrigues (2007)?
- Os resultados alcançados pelo algoritmo são comparáveis aos resultados alcançados pelos algoritmos na literatura?

A resposta a tais questionamentos além de validar o algoritmo desenvolvido, através da comparação dos resultados alcançados com os da literatura, possibilita determinar o grau de influência do Conhecimento Histórico no problema de Despacho. Com isso, pode-se ainda estimar a capacidade do algoritmo para resolver problemas correlatos, como o problema de *Unit Commitment* mencionado por Rodrigues (2007), e os problemas de otimização em Engenharia de Produção mencionados anteriormente na seção 2.1.1.

As considerações realizadas por Rodrigues (2007), no desenvolvimento do algoritmo, em relação à portabilidade e manutenibilidade foram consideradas. Desse modo o algoritmo estendido foi implementado na mesma linguagem de programação, Java versão 5.0. O ambiente de desenvolvimento utilizado foi o Eclipse devido à habilidade da autora com a ferramenta.

O pseudocódigo a seguir apresenta os passos realizados pelo modelo computacional desenvolvido por Rodrigues (2007).

Algoritmo 3: Pseudocódigo do algoritmo implementado (Rodrigues, 2007).

Início

$t \leftarrow 0$

Criar Espaço de Crença

Inicializar População

Avaliar População Inicial

Enquanto não atender condição de término faça

Início

Selecionar Pais

Gerar novos indivíduos pelas Funções de Influência

Avaliar os novos indivíduos

Ajustar espaço de crenças considerando função de aceitação

Selecionar indivíduos para a Próxima Geração

Atualizar Espaço de Crença

Atualizar Parâmetros

Fim Enquanto

Fim

A execução do algoritmo é iniciada pela criação do espaço de crenças o qual engloba a inicialização dos tipos de conhecimentos envolvidos e das probabilidades de uso dos mesmos. O passo seguinte é a inicialização da população de indivíduos que será evoluída. É realizada uma representação real, em que cada gene do cromossomo armazena o valor de uma potência gerada. A Equação 12 é utilizada para a inicializar aleatoriamente a população (Rodrigues, 2007).

$$ind_{i,j} = lim_inf_j + (RANDOM() * (lim_sup_j - lim_inf_j)) \quad \forall i, j \quad (12)$$

Em que:

- a) $ind_{i,j}$: é o j -ésimo gerador (componente) do i -ésimo indivíduo;
- b) lim_inf_j : limite mínimo de produção do j -ésimo gerador;
- c) $RANDOM()$: função que retorna um valor real entre 0 e 1 segundo uma distribuição uniforme;
- d) lim_sup_j : limite máximo de produção do j -ésimo gerador;

O terceiro passo é a avaliação da população inicial. O valor da função objetivo é dada pela Equação 13, apresentada por Rodrigues (2007).

$$\begin{aligned}
 aptidao = & (\alpha) * \left(\sum_{i=1}^n (a_i * ind_{k,i}^2 + b_i * ind_{k,i} + c_i) \right) + \\
 & (1 - \alpha) * \left(\sum_{i=1}^n (A_i * ind_{k,i}^2 + B_i * ind_{k,i} + C_i) \right) \quad \forall k
 \end{aligned}
 \tag{13}$$

Em que:

- a) *aptidao*: representa a aptidão do *k*-ésimo indivíduo;
- b) α : é o peso dado a otimização dos custos. $1 - \alpha$ é o peso dado a otimização da emissão de poluentes;
- c) $ind_{k,i}$: potência do *i*-ésimo gerador do *k*-ésimo indivíduo;
- d) a_i, b_i, c_i : parâmetros da otimização dos custos;
- e) A_i, B_i, C_i : parâmetros da otimização da emissão de poluentes;

Após a avaliação da população inicial o algoritmo entra no laço de repetição que é executado até a condição de parada ser atingida. Então ocorre a seleção dos pais, que é realizada por um torneio que favorece os indivíduos factíveis com bom valor de aptidão e os indivíduos infactíveis que violam pouco a restrição de demanda mínima, dada pela Equação 14.

$$\begin{aligned}
 violacao = VD - \sum_{i=1}^n ind_{k,i}, \quad & \text{se } \sum_{i=1}^n ind_{k,i} < VD \\
 violacao = 0, \quad & \text{caso contrário}
 \end{aligned}
 \tag{14}$$

Em que:

- a) *violacao*: valor que falta para completar a demanda mínima do sistema;
- b) *VD*: valor da demanda mínima;
- c) $Ind_{k,i}$: valor da potência do *i*-ésimo gerador do *k*-ésimo indivíduo.

A geração dos filhos é realiza através da aplicação das funções de influência e a avaliação ocorre do mesmo modo que os indivíduos da população inicial. As funções de influência

utilizam o conhecimento armazenado durante a evolução no espaço de crenças (Rodrigues, 2007).

Em seguida é realizada a seleção dos indivíduos para a próxima geração e posteriormente é feita a atualização do espaço de crenças com os conhecimentos extraídos da população. Por fim, é realizada a atualização dos parâmetros do algoritmo. Os processos de seleção dos pais até a atualização dos parâmetros ocorrem até que a condição de parada do algoritmo seja satisfeita.

3.1 Espaço Populacional

O Espaço Populacional, como em todos os métodos de CE, apresenta um conjunto de indivíduos onde cada indivíduo possui um conjunto de características independentes dos outros, com as quais é possível determinar sua aptidão. O processo de evolução nesse espaço consiste no material genético que os descendentes herdam de seus pais, o que o caracteriza como responsável pela micro evolução do algoritmo.

Nesse trabalho o Espaço Populacional permanece o mesmo apresentado por Rodrigues (2007), implementado sob a forma de um AG. Os operadores genéticos são variações do *crossover* aritmético e da mutação gaussiana. A seleção dos pais é realizada por meio do torneio e a seleção dos indivíduos da próxima geração é feita através do método de substituição geracional.

3.2 Espaço de Crença

O Espaço de Crença, responsável pela macro-evolução, armazena o conhecimento adquirido (experiência) pelos indivíduos através das gerações, e uma vez codificado e armazenado, serve para guiar o comportamento dos indivíduos que pertencem a uma população.

Nesse trabalho será incorporado ao AC implementado por Rodrigues (2007), que contém o Conhecimento Situacional, Conhecimento Normativo e Conhecimento Situacional/Normativo, o Conhecimento Histórico. Desse modo o Espaço de Crença do AC estendido é composto por quatro tipos de conhecimentos: Conhecimento Situacional,

Conhecimento Normativo, Conhecimento Situacional/Normativo e Conhecimento Histórico. As seções seguintes abordam detalhes da influência de cada um desses conhecimentos.

A integração do nível micro-evolutivo e o macro-evolutivo é realizada pelo Protocolo de Comunicação, que é o responsável por ditar as regras do tipo de informação que podem ser trocadas entre os espaços. Os Protocolos de Comunicação (Função de Aceitação e Funções de Influência) implementados por Rodrigues (2007) são mantidos. A Função de Aceitação é Dinâmica, ou seja, a quantidade de indivíduos em cada geração é variável. A Função de Influência Principal é usada para escolher qual tipo de conhecimento será usado para influenciar a geração dos indivíduos e a cada geração essa função é adaptada levando em consideração o sucesso de cada tipo de conhecimento na última geração. A Figura 11 ilustra a integração dos conhecimentos na Função de Influência.

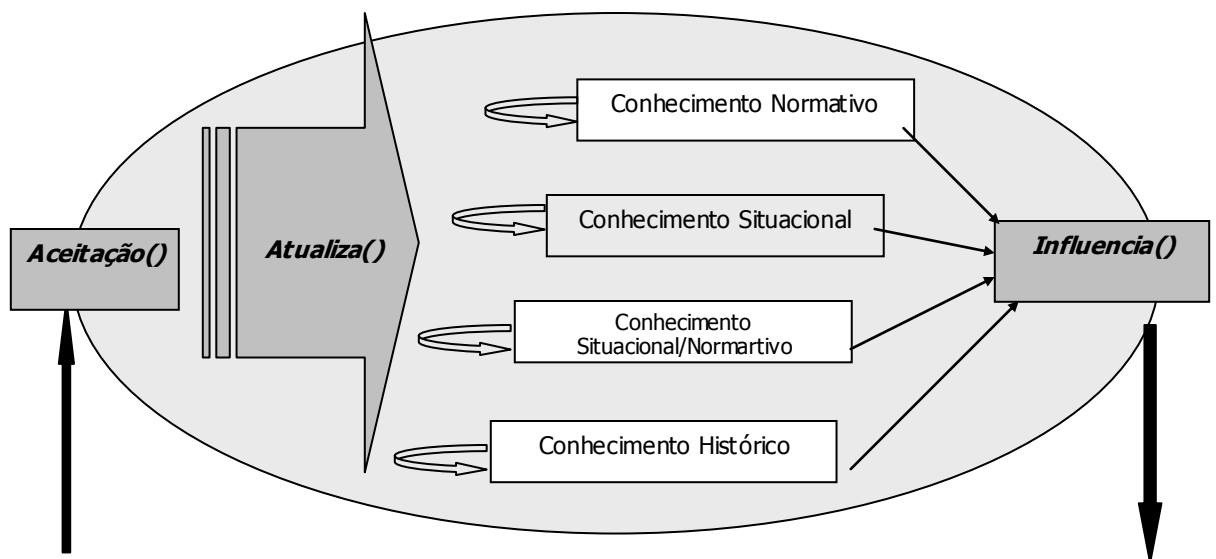


Figura 11 : Esquema da integração dos conhecimentos na Função de Influência (Adaptado de Reynolds, 2003a).

A interação entre os quatro tipos de conhecimento é representada na Figura 12.

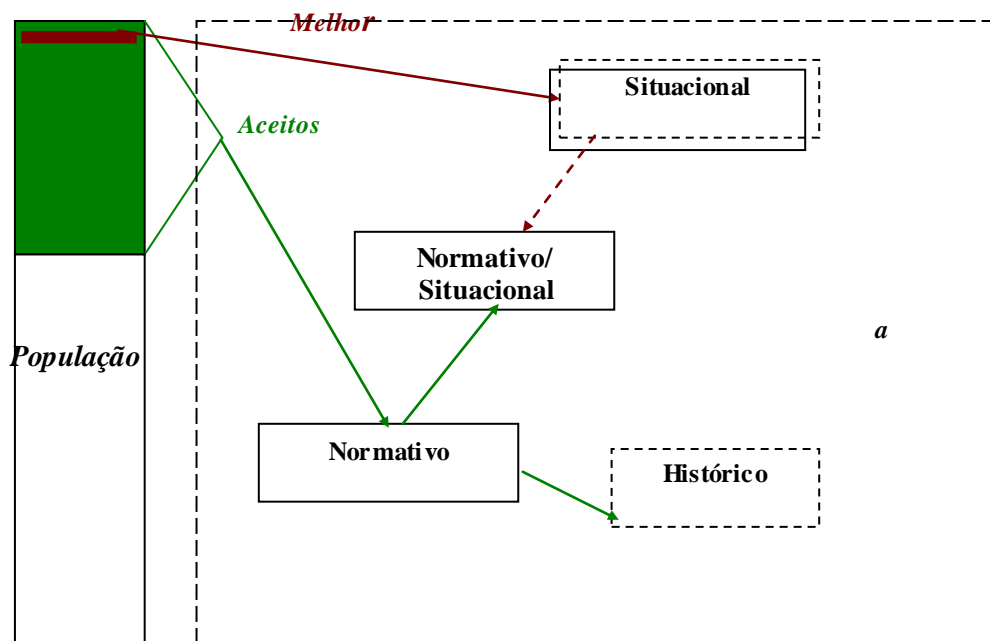


Figura 12 : Interação entre os tipos de conhecimentos (Adaptado de Reynolds, 2003a).

3.3 Categorias de Conhecimento

As categorias de conhecimento que compõe o AC proposto são: Situacional, Normativo Situacional/Normativo e Histórico. Rodrigues (2007) adotou os conhecimentos Situacional, Normativo e Situacional/Normativo por serem os que mais exercem influência na evolução do Espaço Populacional.

A proposta de extensão do AC com a inclusão de Conhecimento Histórico em detrimento ao Conhecimento de Domínio e Conhecimento Topográfico é justificada pelos seguintes motivos:

- a) Dificuldade de extração e representação do Conhecimento de Domínio;
- b) O Conhecimento Histórico oferece uma perspectiva global da mudança, possibilitando que os indivíduos guiados por ele possam consultar os eventos armazenados para auxiliarem suas decisões em relação a qual direção seguir;
- c) O Conhecimento Histórico possibilita a detecção da estagnação na população o que é uma característica importante em ambientes dinâmicos;

- d) O Conhecimento Topográfico, o qual busca explorar diferentes regiões do espaço de busca, utiliza os dados gerados pelo Conhecimento Histórico em sua evolução;
- e) Inviabilidade de tempo para codificação das duas categorias de conhecimento (Histórico e Topográfico) durante o prazo para esse trabalho.

3.3.1 Conhecimento Situacional

Essa categoria de conhecimento armazena um ou mais dos melhores indivíduos encontrados no decorrer do processo evolutivo. O objetivo de armazenar os melhores indivíduos é guiar os demais para moverem-se no sentido deles, como se fosse um exemplo a ser seguido.

Segundo Rodrigues (2007), a atualização do conhecimento situacional corresponde a manter sempre atualizada a lista de melhores indivíduos. Por questões de eficiência computacional esse conhecimento foi codificado como uma árvore rubro-negra. Maiores detalhes sobre a implementação dessa categoria de conhecimento são apresentadas em Rodrigues (2007).

3.3.2 Conhecimento Normativo

O Conhecimento Normativo armazena os intervalos de valores de cada componente (gerador) onde os bons indivíduos se concentram. Esse conhecimento objetiva guiar os indivíduos para se mover para o intervalo certo, caso eles ainda não estejam lá.

A representação computacional desse conhecimento por meio de vetores de quatro posições: valor mínimo e máximo do intervalo e suas aptidões correspondentes (RODRIGUES, 2007).

3.3.3 Conhecimento Situacional/Normativo

Essa categoria de conhecimento engloba conceitos dos Conhecimentos Situacional e Normativo. Não há um método para atualização desse conhecimento. A seleção dos indivíduos que participarão dos operadores segue as características de escolha do Conhecimento Situacional e a forma de influência segue as regras aplicadas no Conhecimento Normativo (Rodrigues, 2007).

3.3.4 Conhecimento Histórico

O Conhecimento Histórico monitora a busca e armazena os eventos importantes que ocorrem no espaço. Neste trabalho é introduzida essa categoria de conhecimento ao AC proposto por Rodrigues (2007), o qual continha em seu espaço de crença o Conhecimento Situacional, Conhecimento Normativo e Conhecimento Situacional/Normativo.

Em termos computacionais esse conhecimento é representado por uma lista dinâmica de n eventos em que cada evento da lista relaciona-se com uma matriz $(2 \times n-1)$. Na primeira linha é armazenada a média das mudanças para i -ésima característica e na segunda a distância média das mudanças para a i -ésima característica.

A lista histórica armazenada todos os indivíduos gerados e aceitos ao longo da evolução. Cada vez que o Conhecimento Histórico é atualizado a lista é ordenada através do método *MergeSort*.

3.4 Adaptação dos Parâmetros

Os parâmetros estabelecidos em Rodrigues (2007) são mantidos, com exceção das probabilidades de se aplicar cada tipo de conhecimento na influência dos operadores. Desse modo um detalhamento maior sobre tais parâmetros pode ser obtido no trabalho de Rodrigues (2007).

Segundo Rodrigues (2007), o controle de parâmetros da Função de Aceitação pode ser classificado como determinístico, pois sua modificação é realizada através de regras, e populacional, pois a mudança do parâmetro afeta toda a população. A Equação 15 formaliza a tal controle.

$$aceitos = taxa_aceitos + (taxa_aceitos / geracao) \quad (15)$$

Em que:

- a) *Aceitos*: percentual de indivíduos a serem aceitos para atualização do espaço de crenças;
- b) *Taxa_aceitos*: determina o percentual mínimo de aceitos;

c) *Geração*: número da geração atual.

A atualização das taxas de mutação e *crossover* são representadas pelas Equações 16 e 17.

$$\text{taxaMutacao} = 0.1 + 0.8 * (0.9 * \text{taxaMutacao} + 0.1 * \text{sucessoMutacao} / \text{sucessoOperadores}) \quad (16)$$

$$\text{taxaCrossover} = 0.1 + 0.8 * (0.9 * \text{taxaCrossover} + 0.1 * \text{sucessoCrossover} / \text{sucessoOperadores}) \quad (17)$$

Em que *taxaMutacao* e *taxaCrossover* correspondem a taxa de Mutação e de *Crossover* e *sucessoMutacao*, *sucessoCrossover* e *sucessoOperadores* são respectivamente, a quantidade de sucessos obtidos pelos operadores de mutação, *crossover* e a soma dos dois.

Rodrigues (2007) destaca que a probabilidade de se aplicar cada tipo de conhecimento na influência dos operadores também é um tipo de controle de parâmetros adaptativo e populacional e apresenta regras parecidas com as utilizadas para adaptar as taxas de mutação e *crossover*.

As Equações 18, 19, 20 e 21 apresentam a formulação matemática que determina a probabilidade de se utilizar os conhecimentos Situacional, Normativo, Situacional/Normativo e Histórico, que é a categoria de conhecimento introduzida por este trabalho.

$$\text{probabilidadeSituacional} = 0.1 + 0.6 * \text{sucessoSituacional} / \text{sucessoConhecimentos} \quad (18)$$

$$\text{probabilidadeNormativo} = 0.1 + 0.6 * \text{sucessoNormativo} / \text{sucessoConhecimentos} \quad (19)$$

$$\text{probabilidadeSituacionalNormativo} = 0.1 + 0.6 * \text{sucessoSituacionalNormativo} / \text{sucessoConhecimentos} \quad (20)$$

$$\text{probabilidadeHistorico} = 0.1 + 0.6 * \text{sucessoHistorico} / \text{sucessoConhecimentos} \quad (21)$$

Em que *probabilidadeSituacional*, *probabilidadeNormativo*, *probabilidadeSituacionalNormativo* e *probabilidadeHistorico* são as probabilidades de aplicação das influências Situacional, Normativo, Situacional/Normativo e Histórico respectivamente e *sucessoSituacional*, *sucessoNormativo*, *sucessoSituacionalNormativo*, *sucessoHistorico* e *sucessoConhecimentos* correspondem aos sucessos obtidos pelos

conhecimentos Situacional, Normativo, Situacional/Normativo, Histórico e pela soma dos anteriores, respectivamente.

4 Simulações e Resultados

A validação do método proposto foi realizada em três casos extraídos da literatura e utilizados em Rodrigues (2007). Foram utilizados dois casos do problema de despacho econômico (caso de 3 e caso de 13 geradores) e um caso do problema do despacho econômico/ambiental (caso de 6 geradores).

Em todos os casos foram utilizados os seguintes conjuntos de parâmetros, os quais foram determinados de modo empírico:

1. Tamanho da população igual a 100.
2. Taxa de cruzamento inicial igual a 90%.
3. Taxa de mutação igual a 10%.
4. Taxa de aceitação igual a 20%.
5. Probabilidade inicial de influência pelo Conhecimento Situacional igual a 25%.
6. Probabilidade inicial de influência pelo Conhecimento Normativo igual a 25%.
7. Probabilidade inicial de influência pelo Conhecimento Situacional/Normativo igual a 25%.
8. Probabilidade inicial de influência pelo Conhecimento Histórico igual a 25%.
9. Número de melhores indivíduos armazenados no Conhecimento Situacional igual a 10.
10. Número de indivíduos armazenados no Conhecimento Histórico igual a 10.
11. Critério de parada igual a 3000 gerações sem melhorias no valor de aptidão do melhor indivíduo. O valor de 3000 gerações sem melhorias foi estabelecido por Rodrigues (2007) após a aplicação de alguns testes estatísticos para verificar o impacto da variação do critério de parada.

Os parâmetros de 2 a 8 são ajustados automaticamente ao longo da evolução e exercem pouca influência nos resultados finais alcançados pelo algoritmo, conforme pode ser observado nas seções seguintes.

Os resultados obtidos serão comparados com os alcançados em Rodrigues (2007) para que se possa determinar a influência do Conhecimento Histórico. Em Rodrigues (2007) foi elaborado um Algoritmo Cultural utilizando três categorias de Conhecimento: Conhecimento Situacional, Conhecimento Normativo e Conhecimento Situacional/Normativo.

4.1 Despacho Econômico

Essa seção aborda problemas relacionados com alocação ótima da demanda de energia elétrica entre as unidades geradoras disponíveis tendo como foco apenas a minimização dos custos de geração de energia. Como apresentado em Rodrigues (2007), para esses problemas o valor de alfa (α) foi setado como 1.0, o que indica que o valor da aptidão apresenta dependência apenas das variáveis que medem o custo.

Os tópicos seguintes apresentam as simulações e resultados para os Casos de 3 e 13 Geradores, respectivamente.

4.1.1 Caso 3 Geradores

O caso de Despacho Econômico com 3 geradores utilizados nesse trabalho é o mesmo usado em Rodrigues (2007). A Tabela 1 apresenta as características do problema (coeficientes característicos da curva de entrada-saída dos geradores e limites operacionais). A demanda mínima a ser atendida nesse caso é igual a 850 MW.

Tabela 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

Rodrigues (2007) aplicou testes estatísticos, com confiabilidade de 95%, aos resultados obtidos com diferentes critérios de parada para verificar o impacto da variação do mesmo. A partir da análise dos resultados do teste estatístico Rodrigues (2007) estabeleceu-se o uso do critério de parada igual a 3000 gerações sem melhoria. O critério de parada utilizado no AC estendido segue o padrão adotado por Rodrigues (2007) de 3000 gerações sem melhoria.

Nas Tabelas 2 e 3 o resultado alcançado com o Algoritmo Cultural estendido é comparado com os melhores resultados obtidos em (RODRIGUES, 2007) (AC), (SAMEDI, 2004) (Algoritmo Genético Híbrido - AGH e Algoritmo Genético Híbrido Co-Evolutivo - AGHCOE) e (SINHA;CHAKRABARTI;CHATTOPADHYAY *apud* RODRIGUES, 2007) (Algoritmo Genético com elitismo e penalidade – AG + E + P).

Tabela 2: Alocação das Potências – Caso 3 Geradores.

Resultados	P₁(MW)	P₂(MW)	P₃(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	389,0240	122,8118	338,1710	850,0069
AC estendido	392,0771	124,1298	333,7955	850,0024

Tabela 3: Melhor Valor de Custo Obtido – Caso 3 Geradores.

Resultados	Valor da Função Objetivo (\$/h)
AGH	8.045,41
AGHCOE	7.961,58
AC + E + P	8.194,36
AC	8.194,47
AC estendido	8.194,40

Conforme pode ser observado nas tabelas acima, o resultados obtido pelo AC estendido foi melhor que o obtido em (RODRIGUES, 2007), se aproximou ainda mais do resultado alcançado em (SINHA;CHAKRABARTI; CHATTOPADHYAY *apud* RODRIGUES, 2007) e inferior àqueles alcançados em (SAMEDI, 2004).

O comportamento do AC estendido em relação à média dos indivíduos encontrados geração a geração é ilustrado na Figura 13. Através da análise dessa Figura é possível notar que para algumas gerações o custo apresentado é menor que o custo mínimo exposta na Tabela 4, isso ocorre porque a população fica oscilando entre indivíduos factíveis e infactíveis.

Segundo Coello e Becerra (2002), os melhores valores encontram-se na fronteira de factibilidade do espaço de busca. Com isso podemos verificar que o Algoritmo Cultural Estendido está explorando boas regiões do espaço de busca.

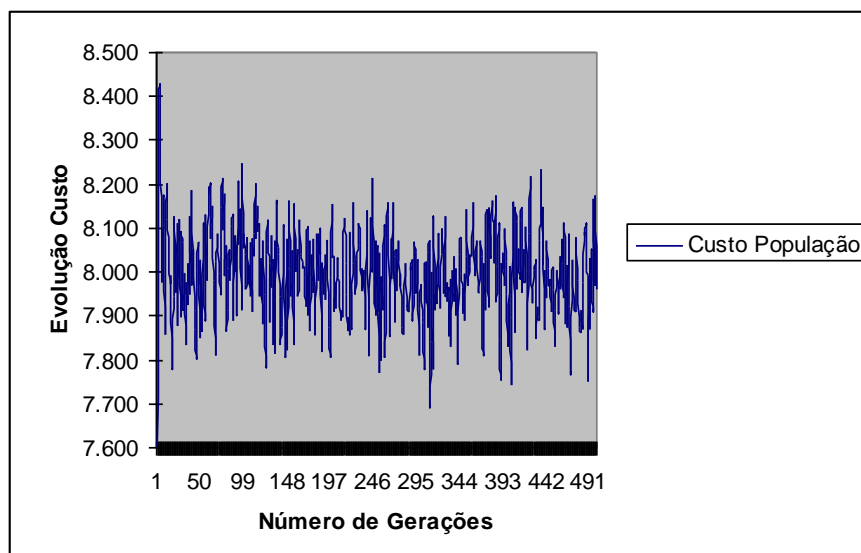


Figura 13 :Gráfico da média inicial de custo do melhor indivíduo – Caso 3 Geradores.

A Figura 14 apresenta o gráfico da média inicial de custo do melhor indivíduo obtido por Rodrigues (2007).




Figura 14 :Gráfico da média inicial de custo do melhor indivíduo – Caso 3 Geradores (Rodrigues, 2007).

A evolução geração a geração do melhor indivíduo encontrado até aquela geração é apresentada na Figura 15. Através dessa Figura podemos observar que nas primeiras gerações o algoritmo já converge para as boas soluções.

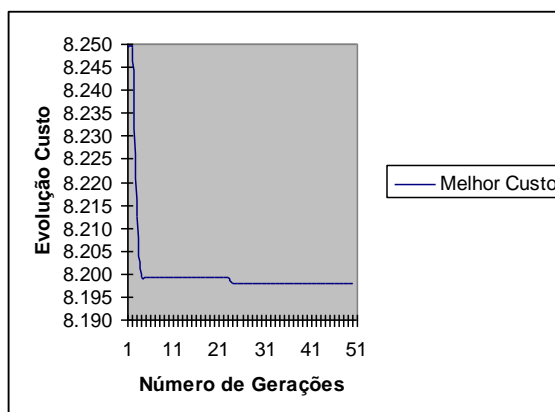


Figura 15 : Gráfico dos melhores custos do melhor indivíduo – Caso 3 Geradores.

A Figura 16 representa o gráfico dos melhores custos do melhor indivíduo obtido por Rodrigues (2007).

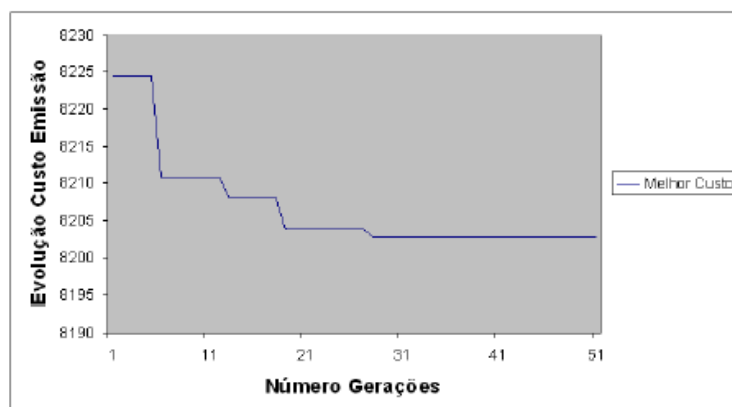


Figura 16 : Gráfico dos melhores custos do melhor indivíduo – Caso 3 Geradores (Rodrigues, 2007).

A Figura 17 ilustra que o algoritmo é capaz de encontrar rapidamente um equilíbrio entre as taxas de mutação e cruzamento ao longo das gerações. Após encontrar o equilíbrio as taxas desses operadores oscilam de modo suave ao redor desses valores.




Figura 17 :Gráfico do início da evolução dos operadores de Mutação e Cruzamento – Caso 3 Geradores.

O gráfico do início da evolução dos operadores obtido por Rodrigues é apresentado na Figura 18.




Figura 18 :Gráfico do início da evolução dos operadores de Mutação e Cruzamento – Caso 3 Geradores (Rodrigues, 2007).

A evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento é mostrada na Figura 19. Podemos observar que a probabilidade de influência do Conhecimento Situacional/Normativo apresenta uma pequena variação ao longo da evolução, mas ainda assim a probabilidade de influência dessa categoria de conhecimento é significativa. Há uma predominância das funções de influência do Conhecimento Situacional, Conhecimento Normativo e Conhecimento Histórico, sendo que o último é o predominante. Cabe ressaltar que são as grandes oscilações ocorrem conforme os conhecimentos vão sendo atualizados e que essas oscilações permeiam todo o processo evolutivo, evidenciando a capacidade de adaptação às mudanças no espaço de crenças.




Figura 19 :Gráfico do início da evolução dos Conhecimentos – Caso 3 Geradores.

Na Figura 20 é apresentada a evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento obtidas por Rodrigues (2007).

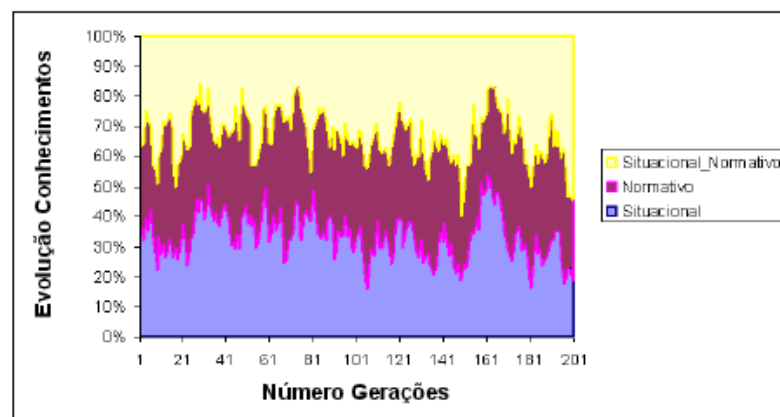


Figura 20 :Gráfico do início da evolução dos Conhecimentos – Caso 3 Geradores (Rodrigues, 2007).

4.1.2 Caso 13 Geradores

Da mesma forma que no trabalho de Rodrigues (2007), o caso de Despacho Econômico com 13 geradores utilizado nesse trabalho é proposto em (KIM et. al, apud RODRIGUES, 2007.

A Tabela a seguir apresenta as características do problema.

Tabela 4: 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

Nas Tabelas 5 e 6 o resultado alcançado com o Algoritmo Cultural estendido é comparado com os melhores resultados obtidos em (RODRIGUES, 2007) (AC), (SAMED, 2004) (Algoritmo Genético Híbrido - AGH e Algoritmo Genético Híbrido Co-Evolutivo - AGHCOE) e (KIM *apud* RODRIGUES, 2007) (Algoritmo Genético com geração elitista à parte e atavismo – AG + GE + AT).

Tabela 5: Alocação das Potências – Caso 13 Geradores.

Resultados	AGH	AGHCOE	AC	AC Estendido
P₁(MW)	651,1452	735,6263	679,2551	681,3252
P₂(MW)	319,9820	337,4955	359,8672	352,4325
P₃(MW)	320,4637	292,6257	357,2368	358,0187
P₄(MW)	137,7761	146,7135	154,8137	149,6715
P₅(MW)	156,6884	177,3462	158,0946	159,0034
P₆(MW)	147,0077	131,5521	155,8520	160,3485
P₇(MW)	159,1650	154,1975	149,1697	142,0729
P₈(MW)	145,3784	159,5506	146,8364	153,1297
P₉(MW)	151,5512	167,3398	168,7979	174,3853
P₁₀(MW)	82,2596	60,6778	40,0181	38,1694
P₁₁(MW)	86,3206	74,6819	40,0000	41,1760
P₁₂(MW)	82,8938	56,5370	55,0175	56,0375
P₁₃(MW)	79,3682	25,6558	55,0488	54,2367
P_{total}(MW)	2.520,0000	2.520,0000	2.520,0084	2.50,0073

Tabela 6: 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	24.052,10
AC estendido	24.052,07

Os resultados obtidos pelo Algoritmo Cultural estendido são muito próximos aos resultados alcançados pelo Algoritmo Cultural e pelo GA + GE + AT, sendo que o AC estendido é melhor. Ao comparar ao AGH e AGHCOE a diferença torna-se mais acentuada em sentido favorável ao AC estendido.

Na Figura 21 é possível observar que o algoritmo a exploração do algoritmo fica oscilando entre indivíduos factíveis e infactíveis próximos ao valor sub-ótimo encontrado.

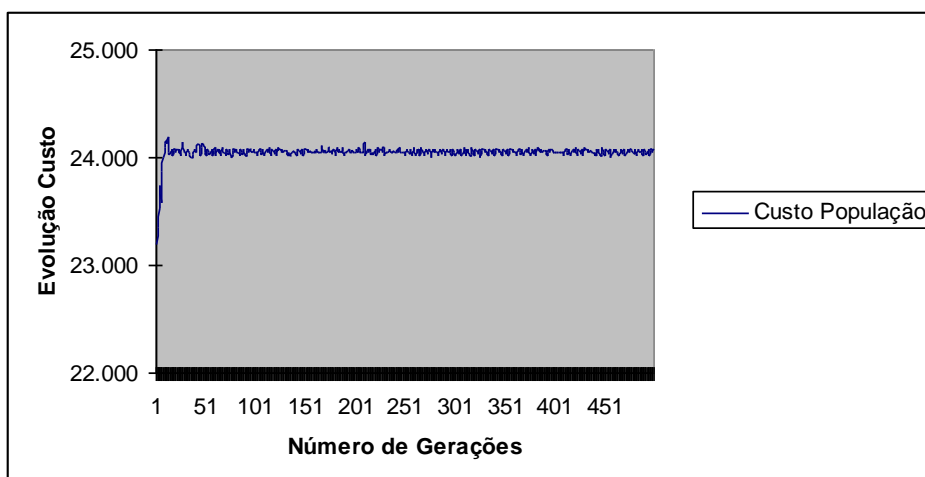


Figura 21 :Gráfico da média inicial de custo do melhor indivíduo – Caso 13 Geradores.

A Figura 22 mostra o gráfico da média inicial de custo do melhor indivíduo obtido por Rodrigues (2007).




Figura 22 :Gráfico da média inicial de custo do melhor indivíduo – Caso 13 Geradores (Rodrigues, 2007).

A Figura 23 apresenta a evolução do melhor indivíduo encontrado até o momento. Podemos observar que em poucas gerações o AC estendido converge para boas soluções.




Figura 23 :Gráfico dos melhores custos do melhor indivíduo – Caso 13 Geradores.

Na Figura 24 é apresentada a evolução do melhor indivíduo obtida por Rodrigues (2007).

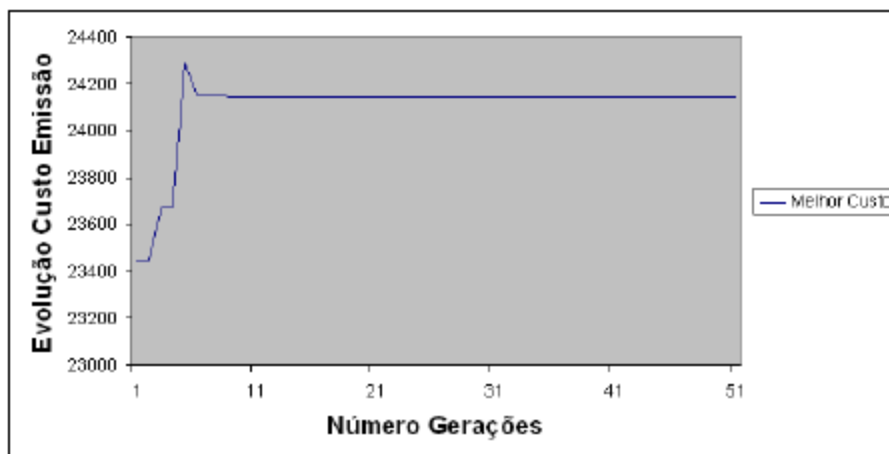


Figura 24 :Gráfico dos melhores custos do melhor indivíduo – Caso 13 Geradores (Rodrigues, 2007).

A Figura 25 ilustra o ajuste das taxas de mutação e cruzamento ao longo das gerações, onde podemos observar que há uma rápida convergência para os valores ótimos, e após isso ocorrem leves oscilações.




Figura 25 :Gráfico do início da evolução dos operadores de Mutação e Cruzamento – Caso 13 Geradores.

Na Figura 26 é apresentada a evolução dos operadores encontrados por Rodrigues (2007).




Figura 26 :Gráfico do início da evolução dos operadores de Mutação e Cruzamento – Caso 13 Geradores (Rodrigues, 2007).

A evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento é mostrada na Figura 27. Podemos observar que há uma predominância das funções de influência do Conhecimento Situacional, Conhecimento Normativo e Conhecimento Histórico, no entanto a contribuição do Conhecimento Situacional/Normativo é significativa.




Figura 27 :Gráfico do início da evolução dos Conhecimentos – Caso 13 Geradores.

A evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento encontrada por Rodrigues (2007) é apresentada na Figura 28.

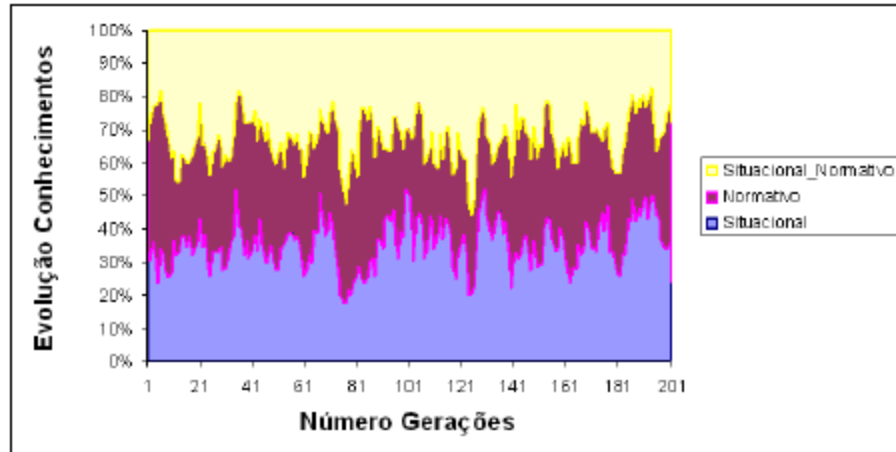


Figura 28 :Gráfico do início da evolução dos Conhecimentos – Caso 13 Geradores (Rodrigues, 2007).

4.2 Despacho Econômico/Ambiental

O Despacho Econômico/Ambiental é um problema multi-objetivo, desse modo não apresenta uma única solução. As simulações realizadas objetivam aproximar uma curva de soluções ótimas, a chamada Fronteira de Pareto. Para que essa curva pudesse ser elaborada o valor de α varia de 0 a 1 num intervalo de 0,1.

Quando α é igual a 0 corresponde ao Despacho Ambiental e quando α igual a 1 corresponde ao Despacho Econômico. Os valores intermediários referem-se a um balanço entre custo de produção e emissão de poluentes. O critério de parada adotado é o mesmo do Despacho Econômico, ou seja, 3000 gerações sem melhoria.

4.2.1 Caso 6 Geradores

O Caso do Despacho Econômico/Ambiental com 6 geradores utilizado nessa monografia é o mesmo usado em Rodrigues (2007), o qual foi proposto em (SAMEDI, 2004). As Tabelas 7 e 8 apresentam as características do problema.

Tabela 7: 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	-0,5116	42,8953
6	0,01799	38,27041	1356,6592	0,00461	-0,5116	42,8953

Tabela 8: 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

Nas Tabelas 9, 10 e 11 são apresentados os melhores valores obtidos para os gerados para cada um dos valores de α utilizados.

Tabela 9: Alocação das Potências pelo AGHCOE – Caso 6 Geradores - DEA.

A	P_1	P_2	P_3	P_4	P_5	P_6	P_{total}
0,0	32,8840	38,4133	82,3074	85,2323	135,00	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	80,0613	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 10: 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

Tabela 11: Alocação das Potências pelo AC Estendido – Caso 6 Geradores - DEA.

α	P_1	P_2	P_3	P_4	P_5	P_6	P_{total}
0,0							500,0
0,1							500,0
0,2							500,0
0,3							500,0
0,4							500,0
0,5							500,0
0,6							500,0
0,7							500,0
0,8							500,0
0,9							500,0
1,0							500,0

Nas Tabelas 12 e 13 o resultado obtido com o Algoritmo Cultural Estendido é comparado com os melhores resultados obtidos em (RODRIGUES,2007) (AC) e (SAMEDI, 2004) (AGHCOE). Podemos notar que o valor de custo obtido pelo AC Estendido é menor que o obtido pelo AC e pelo AGHCOE, exceto para α igual a 0.0. Da mesma forma que o AC, podemos observar que o AC Estendido prioriza custo para valores de α iguais ou superiores a 0,1.

Em relação à função objetivo a Tabela 14 mostra que os valores da função objetivo obtidos pelo Algoritmo Cultural Estendido são levemente melhores do que aqueles obtidos pelo AC e consideravelmente melhores do que os alcançados pelo AGHCOE, o que comprova a superioridade do método para essa instância do problema do Despacho Econômico/Ambiental e a influência do Conhecimento Histórico.

Tabela 12: Custo e Emissão do AGHCOE, AC e AC Estendido – Caso 6 Geradores - DEA.

α	Custo AGHCOE (\$/h)	Custo AC (\$/h)	Custo AC Estendido (\$/h)	Emissão AGHCOE (kg/h)	Emissão AC (kg/h)	Emissão AC Estendido (kg/h)
0,0	27.319,3	27.331,2	27.331,2	256,360	255,960	255,960
0,1	27.191,5	27.041,3	27.041,1	259,460	264,978	264,977
0,2	27.114,8	27.026,6	27.026,5	263,735	267,754	267,753
0,3	27.109,7	27.012,8	27.012,5	264,575	271,886	271,884
0,4	27.104,0	27.014,1	27.013,9	265,284	272,658	272,655
0,5	27.092,7	27.007,8	27.007,7	266,030	275,000	275,002
0,6	27.068,0	27.004,9	27.004,6	268,270	278,768	278,762
0,7	27.059,0	27.004,6	27.004,3	269970	279,225	279,221
0,8	27.051,9	27.004,8	27.004,7	272,207	281,472	281,470
0,9	27.046,9	27.004,3	27.004,2	274,930	283,133	283,131
1,0	27.037,2	27.003,9	27.003,7	276,894	282,212	282,210

Tabela 13: Valor da Função Objetivo AGHCOE, AC e AC Estendido – Caso 6 Geradores - DEA.

α	Função Objetivo AGHCOE	Função Objetivo AC	Função Objetivo AC Estendido
0,0	256,360	255,960	255,960
0,1	2952,664	2942,615	2942,611
0,2	5633,948	5619,53	5619,51
0,3	8318,112	8291,185	8291,184
0,4	11000,770	10968,432	10968,430
0,5	13679,365	13641,461	13641,458
0,6	16348,108	16314,447	16314,447
0,7	19022,291	18986,987	18986,984
0,8	21696,061	21660,134	2166,130
0,9	24369,703	24332,183	24332,181
1,0	27037,200	27003,953	270003,949

O comportamento das médias de custo e emissão, respectivamente, para as gerações iniciais do processo evolutivo quando o valor de α igual a 0.0 são apresentadas nas Figuras 29 e 30. Podemos notar que logo nas primeiras gerações os valores se aproximam dos valores ótimos e a partir daí eles oscilam suavemente ao redor desses valores ótimos.




Figura 29 :Gráfico da média de custo – alfa 0.0 – Caso 6 Geradores.




Figura 30 :Gráfico da média de emissões – alfa 0.0 – Caso 6 Geradores.

As Figuras 31 e 32 ilustram o comportamento das médias de custo e emissão, respectivamente, para as gerações iniciais do processo evolutivo em que o valor de α igual a 0.0 encontrados por Rodrigues (2007).




Figura 31 :Gráfico da média de custo – alfa 0.0 – Caso 6 Geradores (Rodrigues, 2007).




Figura 32 :Gráfico da média de emissões – alfa 0.0 – Caso 6 Geradores (Rodrigues, 2007).

Nas Figuras 33 e 34 é possível observar o comportamento dos melhores valores obtidos encontrados durante as primeiras gerações. Esses valores apresentam o mesmo comportamento das médias de emissão e custo, começam distantes dos valores ótimos, mas apresentam uma rápida convergência para eles logo nas primeiras gerações.




Figura 33 :Gráfico dos melhores custo – alfa 0.0 – Caso 6 Geradores.




Figura 34 :Gráfico das melhores emissões – alfa 0.0 – Caso 6 Geradores.

O comportamento dos melhores valores obtidos encontrados durante as primeiras gerações por Rodrigues (2007) pode ser observado e 36.




Figura 35 :Gráfico dos melhores custo – alfa 0.0 – Caso 6 Geradores (Rodrigues, 2007).

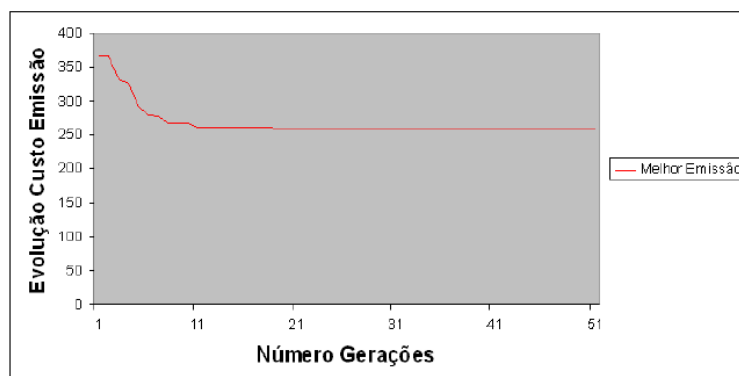


Figura 36 :Gráfico das melhores emissões – alfa 0.0 – Caso 6 Geradores (Rodrigues, 2007).

A evolução das taxas dos operadores de Mutação e Cruzamento é ilustrada na Figura 37, onde pode-se notar que as taxas convergem rapidamente, estabelecendo um equilíbrio.




Figura 37 :Gráfico da evolução do operadores de Mutação e Cruzamento – alfa 0.0 - Caso 6 Geradores.

A Figura 38 apresenta a evolução das taxas dos operadores de Mutação e Cruzamento obtidos por Rodrigues (2007).




Figura 38 :Gráfico da evolução do operadores de Mutação e Cruzamento – alfa 0.0 - Caso 6 Geradores (Rodrigues, 2007).

A Figura 39 retrata a evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento. Podemos observar que há uma predominância das funções de

influência do Conhecimento Situacional, Conhecimento Normativo e Conhecimento Histórico, no entanto a contribuição do Conhecimento Situacional/Normativo é significativa.




Figura 39 :Gráfico do início da evolução dos Conhecimentos – alfa 0.0 - Caso 6 Geradores.

Na Figura 40 é apresentada a evolução das probabilidades de aplicação das funções de influência de cada tipo de conhecimento encontrados por Rodrigues (2007).




Figura 40 :Gráfico do início da evolução dos Conhecimentos – alfa 0.0 - Caso 6 Geradores (Rodrigues, 2007).

As Figura 41, 42 e 43 ilustram as aproximações encontradas para a Fronteira de Pareto pelo AC Estendido, pelo AC e pelo ACHCOE, respectivamente. Ao analisar as figuras podemos notar que não há uma diferença significativa entre o AC e o AC Estendido para a Fronteira de

Pareto. Entretanto pode-se evidenciar que o AC Estendido e o AC são capazes de encontrar uma melhor aproximação para a Fronteira de Pareto do que o AGHCOE.

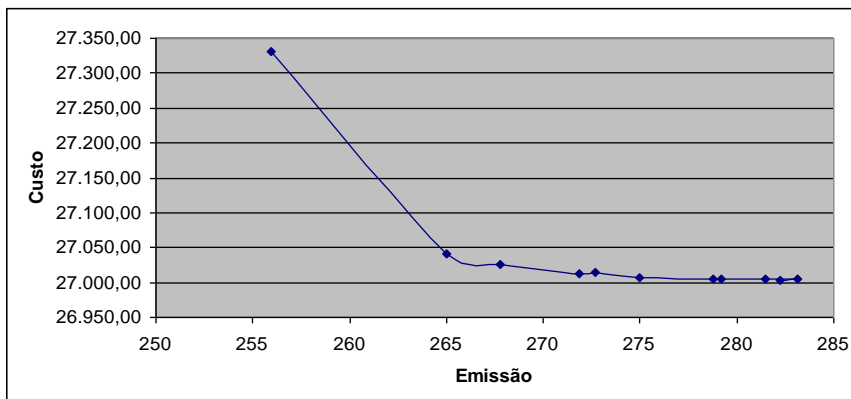


Figura 41 : Aproximação da Fronteira de Pareto Obtida pelo AC Estendido.

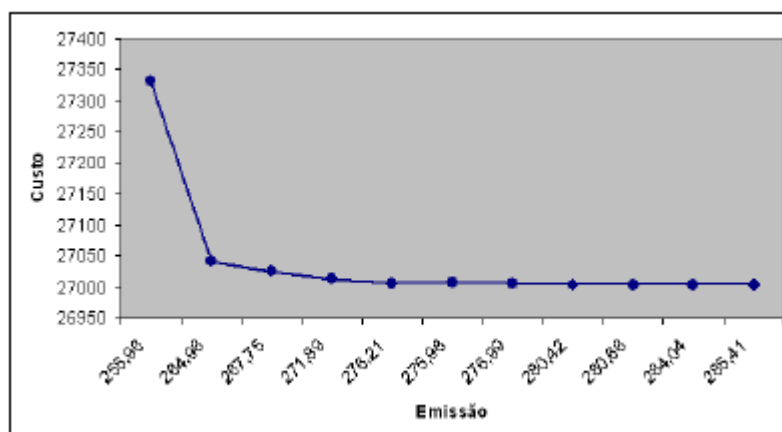


Figura 42 : Aproximação da Fronteira de Pareto Obtida pelo AC.




Figura 43 : Aproximação da Fronteira de Pareto Obtida pelo AGCOE.

CONCLUSÃO

Esta monografia apresentou a extensão de uma abordagem baseada em Algoritmos Culturais e Algoritmos Genéticos para o problema do Despacho Econômico e Despacho Econômico/Ambiental.

O Algoritmo Cultural foi estendido com a adição de uma nova categoria de conhecimento, o Conhecimento Histórico, o qual tem por objetivo monitorar e armazenar os eventos importantes que ocorrem no espaço de busca.

O Conhecimento Histórico foi implementado para monitorar o espaço de busca armazenando as dez soluções de maior ocorrência para que os novos indivíduos possam se desviar desses pontos, em direção e sentido, propiciando assim uma melhor exploração do espaço.

A adição do Conhecimento Histórico melhorou os resultados alcançados, ainda que não tenham sido tão significativas tais melhorias, e preservou a característica já atingida pelo AC proposto em Rodrigues (2007) em que os resultados são comparáveis e em alguns casos superiores aos encontrados na literatura. Tais resultados demonstram o bom comportamento do algoritmo e atestam a sua eficiência.

Embora as melhorias alcançadas não tenham sido tão expressivas, o algoritmo conseguiu explorar melhor o espaço de busca e a implementação do mesmo foi de fundamental importância para que uma nova categoria de conhecimento, o Conhecimento Topográfico, possa ser acrescentada ao espaço de busca.

Com base nos resultados alcançados pode-se concluir que a implementação do Conhecimento Histórico não introduz melhorias muito significativas aos resultados, sendo no caso do Algoritmo Cultural Estendido, melhorias na ordem da segunda casa decimal. Desse modo antes de escolher as categorias de conhecimento a serem codificadas é importante avaliar o problema em questão e verificar que nível de precisão é exigido.

Nos casos em que as melhorias de ordem decimal são importantes é válido implementar o Conhecimento Histórico, caso contrário é importante realizar a implementação de outras categorias de conhecimento.

Como trabalho futuro podemos vislumbrar:

- Implementação de outras categorias de conhecimento, no caso o Conhecimento Topográfico;
- Estudar a hibridização com outros métodos embora os Algoritmos Culturais sejam híbridos por natureza;
- Realizar testes utilizando outra metodologia para a implementação do espaço populacional;
- Considerar o efeito de ponto de válvula, utilizando assim uma versão mais real da função que representa o custo do despacho;
- Levar em consideração as restrições de segurança da rede elétrica e as perdas de energia durante o despacho;
- Realizar estudos mais aprofundados para ajustar os parâmetros;
- Aplicar a metodologia de Algoritmos Culturais em problemas de otimização em engenharia de produção, tais como os mencionados na seção 2.1.1.

REFERÊNCIAS

- ALMEIDA, A. D. V. B-Spline: CAEP – Algoritmos Culturais para Geração de Trajetórias B-Spline de Robôs Móveis. Dissertação (Mestrado) — PUC-PR, 2005.
- ANDRADE, E. L. Introdução à Pesquisa Operacional. Editora LTC, 3º ed. Rio de Janeiro – RJ 2004.
- ANDRADE, E. C. Um Algoritmo Exato para o Problema de Empacotamento Bidimensional em Faixas. Dissertação (Mestrado) – UNICAMP, 2006.
- ARENALES, M. N.; MORABITO, R.; YANASSE, H.H. Problemas de Corte e Empacotamento. Mini-curso XXXVI SBPO, São João Del Rei- MG, 2004.
- BASTOS, E. A. Otimização de Seções Retangulares de Concreto Armado Submetidas á Flexo-Compressão Oblíqua Utilizando Algoritmos Genéticos. Dissertação (Mestrado) – UFRJ, 2006.
- BECERRA, L.R. Algoritmos Culturales Aplicados a Optimización com Restricciones y Optimización Multiobjetivo. Tese (Mestrado) – Centro de Investigacion y de Estudios Avanzados del Instituto Politécnico Nacional – 2002.
- BECERRA, L. R.; COELLO, C. A. C. Culturizing Differential Evolution for Constrained Optimization. In: Genetic and Evolutionary Computation Conference. [S.l.: s.n.], 2005. p. 27–34.
- BELPIEDE, D. Aplicação de Algoritmos Evolutivos para a Otimização do Fluxo de Potência em Sistemas de Subtransmissão de Energia Elétrica. Dissertação (Mestrado) – USP, 2006.
- CHUNG, C.J. Knowledge-Based Approaches to Self-Adaptation in Cultural Algorithms. PhD theses, Wayne State University, Detroit, Michigan, 1997.
- COELHO, L. S. Fundamentos, Potencialidades e Aplicações de Algoritmos Evolutivos. Minicurso do XXVI SEMAC, 2003 – São Carlos, SP.

- COELHO, L. S. MARIANI, V. C. Programação Evolutiva Híbrida com Algoritmo Cultural e Método de Hooke-Jeeves aplicada em problema de otimização não-linear com restrições. Em Brazilian Symposium on Artificial Neural Networks (SBRN). 8º SBRN, 2004. São Luis – MA.
- DELGADO, M. R. B. Projeto Automático de Sistemas Nebulosos: Uma Abordem Co-Evolutiva. Tese (Doutorado) – Unicamp, 2002.
- FALCONE, M. A. G. Estudo Comparativo entre Algoritmos Genéticos e Evolução Diferencial para Otimização de um Modelo de Cadeia de Suprimento Simplificada. Dissertação (Mestrado) – PUC-PR, 2004.
- GRAVES, S. C. -*A review of production scheduling* - Operations research. Vol. 29, n 4, 1981. Pp. 646-675.
- HARNISCH, I; SANHUEZA, R.; DÍAZ, H. Despacho Econômico com Unidades de característica no convexas empregando algoritmos genéticos. Revista Facultad de Ingenieria, enero-junio, vol. 7. Universidade de Tarapaca, Arica-Chile, p.13-19, 2000.
- 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.
- MICHALEWICZ, Z. Genetic Algorithms + Data Structures = Evolution Programs. 2 edition, Springer Verlag 1999.
- MOGNON, V.R. Algoritmos Genéticos Aplicados na Otimização de Antenas. Dissertação (Mestrado) – UFPR, 2006.
- PENG, B.; REYNOLDS, R. G.; BREWSTER, J. Cultural swarms. IEEE, 2003.
- 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.]: Mc-Graw Hill Press, 1999. cap. An Overview of Cultural Algorithms in cultural algorithms. IEEE, p. 260 – 267, 1997.

- REYNOLDS, R. G. Tutorial on Cultural Algorithms. 2003. IEEE Swarm Intelligence Symposium.
- REYNOLDS, R. G. Cultural swarms: knowledge-driven problem solving in social systems. In: IEEE International Conference on Systems, Man and Cybernetics, p. 3589-3594 vol.4, 2003.
- REYNOLDS, R. G.; CHUNG, C. Fuzzy approaches to acquiring experimental knowledge in cultural algorithms. IEEE, p. 260 – 267, 1997.
- REYNOLDS, R. G.; PENG B; CHE, X.. Knowledge Swarms: Generating Emergent Social Structure in Dynamic Environments. Paper extracted from *Proceedings of the Agent 2005 Conference on Generative Social Processes*, Chicago, October 13-15, 2005.
- RODRIGUES, N. M. Um Algoritmo Cultural para Problemas de Despacho. Dissertação (Mestrado) – UEM, 2007.
- SAMED, M. M. A. Um Algoritmo Genético Híbrido Co-Evolutivo para Resolver Problemas de Despacho. Tese (Doutorado) — UEM, 2004.
- SILVA, A. J. M. Implementação de um Algoritmo Genético Utilizando o Modelo de Ilhas. Dissertação (Mestrado) UFRJ – 2005.
- SONG, Y. H. et al. Environmental/economic dispatch using fuzzy logic controlled genetic algorithms. IEE, v. 144, n. 4, p. 377–382, July 1997.
- STERNBERG, M.; REYNOLDS, R. G. Using cultural algorithms to support reengineering 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. Abordagem de Sistemas Inteligentes para a Solução do Problema de Despacho Econômico de Geração. Dissertação (Mestrado) – UNESP, 2004.
- 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.

Universidade Estadual de Maringá
Departamento de Informática
Curso de Engenharia de Produção
Av. Colombo 5790, Maringá-PR
CEP 87020-900
Tel: (044) 3261-4324 / 4219 Fax: (044) 3261-5874