

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E  
INFORMÁTICA INDUSTRIAL

JOSIEL NEUMANN KUK

UM SISTEMA IMUNE *FUZZY* CULTURAL APLICADO AO  
PROBLEMA DE DESPACHO ECONÔMICO DE ENERGIA  
ELÉTRICA

DISSERTAÇÃO

CURITIBA

2009

JOSIEL NEUMANN KUK

**UM SISTEMA IMUNE *FUZZY* CULTURAL APLICADO AO  
PROBLEMA DE DESPACHO ECONÔMICO DE ENERGIA  
ELÉTRICA**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Ciências, do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, da Universidade Tecnológica Federal do Paraná. Área de Concentração: Informática Industrial.

Orientador: Prof<sup>a</sup>. Dr. Myriam Regattieri de Biase da Silva Delgado

**CURITIBA**

**2009**

Ficha catalográfica elaborada pela Biblioteca da UTFPR, Campus Curitiba

K96

Kuk, Josiel Neumann

Um sistema imune fuzzy cultural aplicado ao problema de despacho econômico de energia elétrica / Josiel Neumann Kuk. — 2009.

133 p. : il. ; 30 cm

Orientador : Myriam Regattieri de Biase da Silva Delgado

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2009

Bibliografia : 113-122

1. Lógica difusa. 2. Sistema imunológico – Simulação por computador. 3. Programação genética (Computação). 4. Energia elétrica. 5. Engenharia elétrica – Dissertações. I. Delgado, Myriam Regattieri de Biase da Silva, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD (22. ed.) 621.3



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

Programa de Pós-Graduação em Eng<sup>a</sup> Elétrica e Informática Industrial  
Av. Sete de Setembro, 3165 - 80230-901 - Curitiba - PR.  
<http://www.cpgei.ct.utfpr.edu.br>

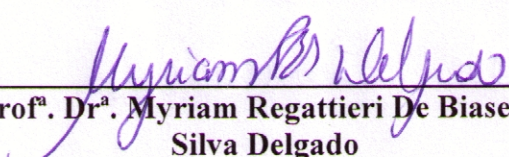



# “Um sistema imune Fuzzy cultural aplicado ao problema de despacho econômico de energia elétrica”

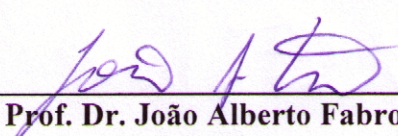
por

**Josiel Neumann Kuk**


Esta Dissertação foi apresentada no dia 28 de maio de 2009, como requisito parcial para a obtenção do grau de MESTRE EM CIÊNCIAS – Área de Concentração: Informática Industrial. Aprovada pela Banca Examinadora composta pelos professores:

  
\_\_\_\_\_  
Prof.<sup>a</sup> Dr.<sup>a</sup> Myriam Regattieri De Biase da  
Silva Delgado  
(Orientadora - UTFPR)

  
\_\_\_\_\_  
Prof. Dr. Leandro dos Santos Coelho  
(PUC-PR)

  
\_\_\_\_\_  
Prof. Dr. João Alberto Fabro  
(UTFPR)

Visto e aprovado para impressão:

  
\_\_\_\_\_  
Prof. Dr. Humberto Remígio Gamba  
(Coordenador do CPGEI)

À minha esposa Tálita, com muito amor.

## **AGRADECIMENTOS**

Mesmo tendo como princípio que atitudes falam mais do que palavras, gostaria de deixar registrado aqui meus agradecimentos às pessoas que, direta ou indiretamente, me ajudaram para o término desse trabalho:

Agradeço imensamente à minha orientadora Myriam por tudo aquilo que me ensinou: conhecimento técnico, crescimento profissional, crescimento pessoal; muito obrigado pela paciência nos meus momentos de desatenção e por minhas limitações. Agradeço também ao seu marido Armando pelas correções. Obrigado por tudo!

Um agradecimento muito especial aos meus amigos, padrinhos e professores Richard e Carol: muito obrigado por toda ajuda e por abrirem mão do precioso tempo de vocês para auxiliarem nesse trabalho. O crescimento perto de vocês é inevitável!

Agradeço muito à minha esposa Tálita por sempre me apoiar, me incentivar e me ajudar em todos os momentos. Você foi muito importante para o término desse trabalho. Te amo!

Agradeço aos meus pais e irmão por todo apoio e todo amor dedicado à minha pessoa. Muito obrigado, amo muito vocês! Agradeço também aos demais familiares que muito me apoiaram para que esse trabalho fosse concluído.

Agradeço a todas as pessoas que, de uma forma ou outra, me ajudaram: não irei arriscar descrever o nome de todos (por serem muitos!) por receio de esquecer de alguém, mas saibam que vocês foram muito importantes nessa caminhada.

Agradeço à Capes pelo apoio financeiro para que este trabalho pudesse ser concluído.

E, acima de tudo, agradeço a Deus por me conceder a capacidade para realizar esse trabalho e por colocar pessoas tão importantes em minha vida!

“Se consigo ver mais longe é por estar nos ombros de Gigantes.”  
-Isaac Newton

## RESUMO

KUK, Josiel Neumann. Um Sistema Imune *Fuzzy* Cultural Aplicado ao Problema de Despacho Econômico de Energia Elétrica. 133 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2009.

Este trabalho tem como objetivo principal a proposição de um sistema híbrido baseado em Computação Natural que seja capaz de solucionar, de forma eficiente, diferentes instâncias do problema de Despacho Econômico de Energia Elétrica com efeito de ponto de válvula. Para isso está sendo proposta uma abordagem baseada em um Algoritmo Cultural, o qual tem como espaço populacional um Algoritmo Imunológico Artificial. No espaço de crenças são utilizados quatro tipos de conhecimentos: situacional, normativo, topográfico e histórico. Nos protocolos de comunicação, a função de aceitação é dinâmica e a função de influência é baseada em um Sistema de Inferência *Fuzzy*, o qual define o possível percentual de aplicação de cada um dos conhecimentos. Para avaliar o paradigma proposto são utilizadas três instâncias do problema do Despacho Econômico de Energia Elétrica. Os resultados mostram que a introdução de um Sistema de Inferência *Fuzzy*, auxiliando a decisão do tipo de conhecimento a ser aplicado, pode trazer benefícios nos resultados. Na comparação com os resultados reportados na literatura, observa-se que a abordagem, apesar de não ter seus parâmetros otimizados para cada caso, é competitiva com os algoritmos do estado-da-arte.

**Palavras-chave:** Algoritmos Culturais, Sistema Imunológico Artificial, Sistema de Inferência *Fuzzy*, Problema do Despacho Econômico de Energia Elétrica



## ABSTRACT

KUK, Josiel Neumann. A Fuzzy Cultural Immune System for Economic Load Dispatch Problem. 133 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2009.

The main objective of this work is the proposal of a hybrid system based on Natural Computing approaches, which is capable of efficiently solving different instances of the Economic Load Dispatch problem of electrical energy with valve-point effect. For this purpose it is developed a new approach based on Cultural Algorithm, which has as its population space an Artificial Immune System. In the belief space, we use four knowledge types: situational, normative, topographical and historical. In the communication protocols, the acceptance function is dynamic and the principal influence function is based on a Fuzzy Inference System which defines the probable percentage of application of each knowledge type. Three instances of the Economic Load Dispatch with Non-smooth Cost Functions problem are used to evaluate the proposed paradigm. The results show that the introduction of fuzzy systems to support the decision of which type of knowledge must be applied can bring benefits to the obtained results. Although its parameters were not optimized for each case of study, the proposed algorithm performed likewise the state-of-the-art algorithms.

**Keywords:** Cultural Algorithms, Artificial Immune System, Fuzzy Inference System Economic Load Dispatch with non-smooth cost functions.

## LISTA DE FIGURAS

FIGURA 1 – PRINCÍPIO DA SELEÇÃO CLONAL .....	24
FIGURA 2 – PRINCÍPIO DA REDE IMUNOLÓGICA .....	25
FIGURA 3 – CICLO BÁSICO DO ALGORITMO CULTURAL .....	33
FIGURA 4 – REPRESENTAÇÃO DE UM META-ESPAÇO DE CRENÇAS .....	38
FIGURA 5 – REPRESENTAÇÃO DOS PROTOCOLOS DE COMUNICAÇÃO ....	41
FIGURA 6 – REPRESENTAÇÃO DO CONHECIMENTO SITUACIONAL .....	43
FIGURA 7 – REPRESENTAÇÃO DO CONHECIMENTO NORMATIVO .....	44
FIGURA 8 – REPRESENTAÇÃO DO CONHECIMENTO TOPOGRÁFICO .....	46
FIGURA 9 – REPRESENTAÇÃO DO CONHECIMENTO TOPOGRÁFICO .....	47
FIGURA 10 – REPRESENTAÇÃO DO CONHECIMENTO HISTÓRICO .....	49
FIGURA 11 – EXEMPLOS DE FUNÇÕES DE PERTINÊNCIA .....	54
FIGURA 12 – EXEMPLOS DE FORMATOS DAS FUNÇÕES DE PERTINÊNCIA .	56
FIGURA 13 – VARIÁVEL LINGUÍSTICA .....	57
FIGURA 14 – INFERÊNCIA NO MODELO LINGUÍSTICO DE MAMDANI .....	63
FIGURA 15 – PARTIÇÃO VARIÁVEL IDADE .....	85
FIGURA 16 – PARTIÇÃO VARIÁVEL DIVERSIDADE .....	86
FIGURA 17 – PARTIÇÃO VARIÁVEL QUALIDADE .....	87
FIGURA 18 – REGRAS DO SISTEMAS DE INFERÊNCIA <i>FUZZY</i> .....	88
FIGURA 19 – PARTIÇÃO VARIÁVEL APLICARSITUACIONAL .....	89
FIGURA 20 – REPRESENTAÇÃO DO CONHECIMENTO HISTÓRICO .....	94
FIGURA 21 – CONVERGÊNCIA MELHORES PARA 13 GERADORES E 1800 <i>MW</i>	106
FIGURA 22 – CONVERGÊNCIA MELHORES PARA 13 GERADORES E 2520 <i>MW</i>	107
FIGURA 23 – CONVERGÊNCIA MELHORES PARA 40 GERADORES E 10500 <i>MW</i>	108
FIGURA 24 – CONVERGÊNCIA MÉDIA PARA 13 GERADORES E 1800 <i>MW</i> ...	109
FIGURA 25 – CONVERGÊNCIA MÉDIA PARA 13 GERADORES E 2520 <i>MW</i> ...	110
FIGURA 26 – CONVERGÊNCIA MÉDIA PARA 40 GERADORES 10500 <i>MW</i> ....	111
FIGURA 27 – SIMPLEX NELDER-MEAD: REFLEXÃO E EXPANSÃO .....	131

## LISTA DE TABELAS

TABELA 1	– COMPARAÇÃO ENTRE OS ELEMENTOS BIOLÓGICOS E OS ELEMENTOS DO ALGORITMO. ....	74
TABELA 2	– RESULTADOS OBTIDOS COM 50 INDIVÍDUOS NA POPULAÇÃO: 13 GERADORES E DEMANDA DE 1800 MW .....	93
TABELA 3	– RESULTADOS OBTIDOS COM 100 INDIVÍDUOS NA POPULAÇÃO: 13 GERADORES E DEMANDA DE 1800 MW .....	94
TABELA 4	– RESULTADOS OBTIDOS COM 50 INDIVÍDUOS NA POPULAÇÃO: 13 GERADORES E DEMANDA DE 2520 MW .....	95
TABELA 5	– RESULTADOS OBTIDOS COM 100 INDIVÍDUOS NA POPULAÇÃO: 13 GERADORES E DEMANDA DE 2520 MW .....	95
TABELA 6	– RESULTADOS OBTIDOS COM 50 INDIVÍDUOS NA POPULAÇÃO: 40 GERADORES E DEMANDA DE 10500 MW .....	96
TABELA 7	– RESULTADOS OBTIDOS COM 100 INDIVÍDUOS NA POPULAÇÃO: 40 GERADORES E DEMANDA DE 10500 MW .....	97
TABELA 8	– VALOR DOS GERADORES PARA O MELHOR RESULTADO OBTIDO PARA DEMANDA DE 1800MW E 13 GERADORES (MÉTODO FCISR COM 100 INDIVÍDUOS). ....	108
TABELA 9	– VALOR DOS GERADORES PARA O MELHOR RESULTADO OBTIDO PARA DEMANDA DE 2520MW E 13 GERADORES (MÉTODO IS COM 100 INDIVÍDUOS). ....	108
TABELA 10	– VALOR DOS GERADORES PARA O MELHOR RESULTADO OBTIDO PARA DEMANDA DE 10500MW E 40 GERADORES (MÉTODO FCISR COM 100 INDIVÍDUOS). ....	109
TABELA 11	– COMPARAÇÃO ENTRE OS MÉTODOS PROPOSTOS E OUTRAS ABORDAGENS DA LITERATURA PARA O CASO COM 13 GERADORES E DEMANDA DE 1800 MW. ....	111
TABELA 12	– COMPARAÇÃO ENTRE OS MÉTODOS PROPOSTOS E OUTRAS ABORDAGENS DA LITERATURA PARA CASO COM 13 GERADORES E DEMANDA DE 2520 MW. ....	111
TABELA 13	– COMPARAÇÃO ENTRE OS MÉTODOS PROPOSTOS E OUTRAS ABORDAGENS DA LITERATURA PARA O CASO COM 40 GERADORES E DEMANDA DE 10500 MW. ....	112
TABELA 14	– BASE DE REGRAS PARA O CONHECIMENTO SITUACIONAL.	128
TABELA 15	– BASE DE REGRAS PARA O CONHECIMENTO NORMATIVO. ..	129

TABELA 16 – BASE DE REGRAS PARA O CONHECIMENTO HISTÓRICO. . . .	130
TABELA 17 – BASE DE REGRAS PARA O CONHECIMENTO TOPOGRÁFICO.	131

## LISTA DE SIGLAS

CN	Computação Natural
AC	Algoritmos Culturais
SIA	Sistemas Imunológicos Artificiais
Clonalg	<i>Clonal Selection Algorithm</i>
SI	Sistema Imune
opt-aiNet	<i>Artificial Immune Network for Optimization</i>
dopt-aiNet	<i>Artificial Immune Network for Dynamic Optimization</i>
IFRAIS	<i>Induction of Fuzzy Rules with Artificial Immune Systems</i>
CHARMM	<i>Chemistry at HARvard Macromolecular Mechanics</i>
ARB	<i>Antigenic Recognition Ball</i>
PID	<i>Proportional Integral Derivative Controller</i>
MANETs	<i>Mobile Ad Hoc Network</i>
ED	Evolução Diferencial
AG	Algoritmos Genéticos
PG	Programação Genética
NP	Nuvem ou Enxame de Partícula
SIF	Sistema de Inferência <i>Fuzzy</i>
IS	<i>Immune System</i> ou Sistema Imunológico Artificial Puro
CIS	<i>Cultural Immune System</i> ou Sistema Imunológico Artificial com Algoritmo Cultural
FCIS	<i>Fuzzy Cultural Immune System</i> ou Sistema Imunológico Artificial com Algoritmo Cultural e Função de Influência <i>Fuzzy</i>
FCISp	FCIS com penalidade
FCISr	FCIS com reparação

## LISTA DE ALGORITMOS

1	Algoritmo do Clonalg Padrão .....	p. 25
2	Forma Básica de um Algoritmo Cultural .....	p. 33
3	Algoritmo do SIA Desenvolvido Originalmente .....	p. 74
4	Procedimento de Reparação .....	p. 77
5	Algoritmo Cultural Implementado .....	p. 79

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	MOTIVAÇÃO	16
1.2	OBJETIVOS	17
1.3	CONTRIBUIÇÕES	19
1.4	ORGANIZAÇÃO DA DISSERTAÇÃO	19
<b>2</b>	<b>SISTEMA IMUNOLÓGICO ARTIFICIAL</b>	<b>21</b>
2.1	SISTEMA IMUNOLÓGICO NATURAL	21
2.1.1	Princípio da Seleção Clonal	22
2.1.2	Teoria da Rede Imunológica	24
2.1.3	Recombinação Gênica	25
2.2	CLONALG	25
<b>3</b>	<b>ALGORITMOS CULTURAIS</b>	<b>31</b>
3.1	MODELO BÁSICO DE ALGORITMOS CULTURAIS	32
3.2	ESPAÇO POPULACIONAL E ESPAÇO DE CRENÇAS	35
3.2.1	Espaço Populacional	35
3.2.2	Espaço de Crenças	37
3.3	PROTOCOLOS DE COMUNICAÇÃO	39
3.3.1	Função de Aceitação	39
3.3.2	Função de Influência	40
3.4	TIPOS DE CONHECIMENTOS	42
3.4.1	Conhecimento Situacional	42
3.4.2	Conhecimento Normativo	43
3.4.3	Conhecimento de Domínio	44
3.4.4	Conhecimento Topográfico	44
3.4.5	Conhecimento Histórico	46
<b>4</b>	<b>SISTEMA DE INFERÊNCIA FUZZY</b>	<b>49</b>
4.1	INTRODUÇÃO AOS CONJUNTOS FUZZY	50
4.1.1	Funções de Pertinência	51
4.2	BASE DE DADOS	54
4.3	BASE DE REGRAS	55
4.4	MECANISMOS DE RACIOCÍNIO	57
4.4.1	Inferência Escalonada (Modelo MinMax)	58
4.4.2	Inferência MinMax no Modelo Mamdani	60
<b>5</b>	<b>DESPACHO ECONÔMICO DE ENERGIA ELÉTRICA</b>	<b>63</b>
5.1	MODELO MATEMÁTICO	64
5.2	TRABALHOS CORRELATOS	65
5.2.1	Um Algoritmo Cultural para Problemas do Despacho Econômico e Ambiental de Energia Elétrica	65
5.2.2	Um Sistema Imune Cultural para o Problema do Despacho Econômico	66
5.2.3	Um Algoritmo Cultural com Evolução Diferencial aplicado ao Problema de Despacho Econômico de Energia Elétrica	67

5.2.4	Evolução Diferencial com Algoritmos Culturais aplicados na solução de Problemas de Despacho Econômico .....	68
5.2.5	Um Sistema Imune aplicado a Problemas de Despacho Econômico .....	69
5.2.6	Evolução Diferencial aplicado a Problemas de Despacho Econômico .....	71
<b>6</b>	<b>UM SISTEMA IMUNE FUZZY CULTURAL PARA PROBLEMAS DO DESPACHO ECONÔMICO.....</b>	<b>73</b>
6.1	ESPAÇO POPULACIONAL .....	73
6.2	ESPAÇO DE CRENÇA .....	79
6.2.1	Protocolos de Comunicação: Funções de Aceitação e Influência .....	80
	Função de Aceitação .....	80
	Função de Influência Dinâmica .....	81
	Função de Influência <i>Fuzzy</i> .....	81
6.2.2	Tipos de Conhecimento .....	86
6.2.3	Conhecimento Situacional .....	86
6.2.4	Conhecimento Normativo .....	86
6.2.5	Conhecimento Histórico .....	87
6.2.6	Conhecimento Topográfico .....	89
<b>7</b>	<b>SIMULAÇÕES E RESULTADOS .....</b>	<b>91</b>
7.1	DESCRIÇÃO DOS EXPERIMENTOS .....	91
7.2	COMPARAÇÃO ENTRE AS DIFERENTES ABORDAGENS BASEADAS EM SIA .....	92
7.2.1	Despacho Econômico: 13 geradores e demanda de 1800 MW .....	93
	População com 50 indivíduos .....	93
	População com 100 indivíduos .....	94
7.2.2	Despacho Econômico: 13 geradores e demanda de 2520 MW .....	95
	População com 50 indivíduos .....	95
	População com 100 indivíduos .....	95
7.2.3	Despacho Econômico: 40 geradores e demanda de 10500 MW .....	96
	População com 50 indivíduos .....	96
	População com 100 indivíduos .....	97
7.2.4	Análise Estatística .....	97
	13 geradores e demanda de 1800 MW .....	97
	13 geradores e demanda de 2520 MW .....	98
	40 geradores e demanda de 10500 MW .....	98
7.2.5	Ilustração da convergência dos métodos .....	99
	Convergência dos melhores indivíduos .....	99
	Convergência média dos indivíduos .....	99
7.2.6	Melhores indivíduos .....	107
7.3	COMPARAÇÃO COM OUTROS MÉTODOS DA LITERATURA .....	110
<b>8</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS .....</b>	<b>113</b>
8.1	TRABALHOS FUTUROS .....	114
	<b>REFERÊNCIAS .....</b>	<b>115</b>
	<b>APÊNDICE A – QUASI-SIMPLEX .....</b>	<b>123</b>
	<b>APÊNDICE B – SISTEMA DE INFERÊNCIA FUZZY DESENVOLVIDO .....</b>	<b>126</b>



## 1 INTRODUÇÃO

O objetivo geral deste trabalho é a implementação de um sistema híbrido baseado em Computação Natural que seja capaz de solucionar, de forma eficiente, um conjunto de problemas de despacho (complexo problema de otimização contínua). Mais especificamente, pretende-se unir Algoritmos Culturais, Sistemas Imunológicos Artificiais e Sistemas *Fuzzy* com o intuito de se produzir um sistema que possa se beneficiar da cooperação destes paradigmas na solução de diferentes instâncias do problema de Despacho Econômico de energia elétrica.

O termo sistema híbrido tem sido frequentemente associado a sistemas cujos comportamentos são definidos por entidades ou processos de características distintas (SCHERER, 1996). Dentre os exemplos bem sucedidos da combinação de sistemas oriundos de diferentes áreas de pesquisa, destacam-se os paradigmas inspirados em Computação Natural (CN). Neste trabalho, a terminologia computação natural será empregada para descrever todos os sistemas desenvolvidos com inspiração ou utilização de algum mecanismo biológico ou natural de processamento de informação (De Castro, 2006). Os paradigmas da CN que serão abordados neste trabalho são os Algoritmos Culturais (REYNOLDS, 1994), Sistemas Imunológicos Artificiais (DASGUPTA, 1999) e os Sistemas de Inferência *Fuzzy* (PEDRYCZ; GOMIDE, 2007).

Os Algoritmos Culturais (AC) são algoritmos evolucionários baseados no processo de evolução cultural da humanidade. Os AC foram propostos por Robert Reynolds (REYNOLDS, 1994) como um complemento à metáfora evolutiva utilizada na Computação Evolutiva, metáfora essa que se concentra nos aspectos genéticos da evolução e na teoria da seleção natural proposta por Darwin. Em contrapartida, os Algoritmos Culturais baseiam-se em teorias sociais e arqueológicas que modelam a evolução cultural dos povos (BECERRA; COELLO, 2005).

Já os Sistemas Imunológicos Artificiais (SIA) são compostos por metodologias inteligentes, inspiradas no sistema imunológico biológico, para solução de problemas complexos (DAS-GUPTA, 1999). Para que um sistema seja considerado um sistema imunológico artificial, deve incorporar pelo menos um modelo básico de um sistema imune biológico (como por exemplo: células, moléculas, órgãos). Além disso, este deve incorporar idéias ou conceitos de imunologia teórica e/ou experimental.

Por outro lado, a teoria de conjuntos *fuzzy* foi concebida por Lofti A. Zadeh (ZADEH, 1965) com o objetivo de fornecer uma ferramenta matemática para o tratamento de informações imprecisas ou vagas. Os conjuntos *fuzzy* representam, portanto, uma generalização dos conjuntos clássicos e formam a base teórica para o entendimento dos Sistemas de Inferência *Fuzzy* (SIF).

Os sistemas híbridos resultantes destes três paradigmas da Computação Natural são aplicados a três instâncias do problema do despacho econômico, o qual pode ser caracterizado como um problema de otimização contínua onde deve ser gerada a menor quantidade possível de energia elétrica para suprir a demanda solicitada. Ou seja, o objetivo é minimizar o custo de combustível utilizado nos geradores, mas de forma a garantir a energia necessária para atender todos os consumidores (SINHA; CHAKRABARTI; CHATTOPADHYAY, 2004).

## 1.1 MOTIVAÇÃO

Existe atualmente uma variedade de tecnologias de processamento de informação sendo utilizadas em diferentes domínios de aplicação. Entretanto, torna-se cada vez mais evidente o fato de que muitos problemas não podem ser solucionados através do uso isolado de algumas destas técnicas. Este fato serve como um dos principais incentivos à criação de sistemas híbridos, que possam suprimir as limitações individuais de cada técnica. Estas abordagens híbridas são consideradas metodologias robustas e flexíveis por explorarem a cooperação entre as técnicas.

Neste sentido, a Computação Natural (CN) aparece como uma área importante para o fornecimento de técnicas e modelos cuja aplicação conjunta resulte em sistemas híbridos naturais indicados para a solução de problemas práticos (por exemplo o problema de despacho econômico de energia elétrica). O uso associado dos diferentes paradigmas computacionais da

CN permite, por exemplo, a representação do conhecimento através de uma base de regras e tratamento de incertezas, presentes nos sistemas *fuzzy*; a obtenção de soluções por meio de eficientes métodos de busca, característica dos algoritmos baseados em computação evolutiva; e a autonomia de funcionamento, característica dos sistemas imunológicos artificiais.

Já o problema do Despacho Econômico é de extrema importância, já que é necessário produzir a energia necessária para atender à demanda com custo mínimo, e métodos eficientes de busca e otimização desempenham papel fundamental neste processo de otimização.

Os métodos da Computação Natural (Algoritmos Imunológicos Artificiais e Culturais) foram escolhidos por serem métodos que vêm sendo aplicados de forma satisfatória em problemas de otimização com restrições, caso em que se enquadra o problema do Despacho Econômico; e também por serem técnicas relativamente novas, com muitos pontos em aberto, ainda a serem explorados, como por exemplo a definição dos parâmetros que controlam o algoritmo. Por outro lado, a idéia de se usar sistemas de inferência *fuzzy* parte do princípio que o conhecimento pode ser mais facilmente compreendido de forma linguística.

## 1.2 OBJETIVOS

Conforme já mencionado no início do capítulo, este trabalho tem como objetivo principal a proposta de um algoritmo híbrido baseado em Computação Natural a ser aplicado ao problema do despacho econômico. De forma específica pretende-se:

- implementar um paradigma baseado em Algoritmo Cultural (AC), o qual tem como espaço populacional um Algoritmo Imunológico Artificial (SIA) e utiliza na função de influência um Sistema de Inferência *Fuzzy*;
- implementar variantes do paradigma anterior onde, em cada caso, uma ou mais técnicas são suprimidas. Por exemplo, parte-se da versão completa (SIA + Cultural + *Fuzzy*) denominada sistema imune *fuzzy* cultural e retira-se a parte *fuzzy* resultando em um sistema imune cultural. Em outro caso, parte-se da versão imune cultural e retira-se a parte cultural, resultando na versão imune;

- implementar para a versão completa (SIA + Cultural + *Fuzzy*) duas novas variantes: uma que utiliza o método de reparação para evitar indivíduos inactíveis e outra que utiliza o método da penalidade, o qual penaliza a solução reduzindo o seu *fitness*, em caso de inactibilidade;
- aplicar as diferentes versões geradas na solução de três instâncias do problema do Despacho Econômico de Energia Elétrica com efeito de ponto de válvula:
  - Problema com 13 geradores e demanda de 1800 MW;
  - Problema com 13 geradores e demanda de 2520 MW; e
  - Problema com 40 geradores e demanda de 10500 MW;
- confrontar os melhores paradigmas implementados (aqueles que obtiveram melhores resultados) com diferentes técnicas propostas na literatura<sup>1</sup> para a resolução do mesmo problema.

Neste contexto de aplicação, e considerando-se a abordagem proposta e suas variantes, busca-se avaliar se:

1. o processo de união de AC e SIA traz benefícios em termos de desempenho do sistema híbrido resultante;
2. a inclusão do Sistema de Inferência *Fuzzy* traz ou não ganho para o Algoritmo Cultural baseado em Sistema Imunológico Artificial proposto;
3. para o paradigma imune cultural *fuzzy*, a metodologia de reparação é mais eficiente do que a metodologia de penalidade considerando-se as restrições impostas pelo problema. Ou seja, pretende-se verificar se a permissão de indivíduos inactíveis na população (ainda que penalizados) pode resultar em perda de desempenho.

---

<sup>1</sup>Técnicas de Computação Natural que obtiveram bons resultados até o momento.

### 1.3 CONTRIBUIÇÕES

Esta dissertação traz como contribuição principal a implementação de diferentes paradigmas híbridos baseados em Computação Natural.

Assim, foram geradas quatro abordagens diferentes:

1. Sistema imune ou Sistema Imunológico Artificial puro (IS);
2. Sistema imune cultural ou Sistema Imunológico Artificial com Algoritmo Cultural (CIS);
3. Sistema imune *fuzzy* cultural ou Sistema Imunológico Artificial com Algoritmo Cultural e função de Influência *Fuzzy* (FCIS):
  - FCIS com função de reparação (FCISr);
  - FCIS com função de penalidade (FCISp).

Como principal vantagem dos métodos destaca-se o desempenho satisfatório em diferentes instâncias do problema do despacho econômico para um mesmo conjunto de parâmetros de controle dos algoritmos.

### 1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

O restante da dissertação está dividida em oito capítulos. Após esta introdução, o capítulo 2 traz os conceitos básicos de um sistema Imunológico Artificial o qual será utilizado no espaço populacional do Algoritmo Cultural que está sendo proposto. No capítulo 3 são apresentados os principais conceitos de Algoritmos Culturais, com ênfase para o espaço de crenças e os protocolos de comunicação. O capítulo 4 aborda os princípios básicos dos sistemas *fuzzy* de forma a facilitar o entendimento da base de regras utilizada na função de influência *fuzzy* proposta neste trabalho. O capítulo 5 descreve o problema de Despacho Econômico de Energia Elétrica e o modelo de representação desse problema. O capítulo 6 apresenta a metodologia utilizada nos algoritmos considerados nesse trabalho. As simulações computacionais e a discussão dos

resultados são apresentadas no capítulo 7. Para completar, o capítulo 8 traz as conclusões e os trabalhos futuros.

## 2 SISTEMA IMUNOLÓGICO ARTIFICIAL

A maioria das aplicações baseadas em Sistemas Imunológicos Artificiais (SIA) está focada em três teorias imunológicas principais: seleção clonal (BURNET, 1959), redes imunológicas (ou redes imunes) (JERNE, 1974) e seleção negativa. Os pesquisadores em SIA têm concentrado sua atenção em aprendizado e mecanismos de memória de sistemas imunes (como a teoria da seleção clonal e as redes imunes) e na seleção de detectores para identificar anomalias (tipicamente desenvolvido com a teoria da seleção negativa) (TIMMIS, 2007).

Como a área de SIA é abrangente, este capítulo terá como foco a Teoria da Seleção Clonal e seu algoritmo clássico (Clonalg).

### 2.1 SISTEMA IMUNOLÓGICO NATURAL

A principal função do Sistema Imunológico ou Sistema Imune (SI) natural é proteger o organismo de agentes geradores de doenças e, para isso, utiliza alguns órgãos (medula óssea), células (células B e T) e moléculas (anticorpos e MHC - complexo de histocompatibilidade principal). Cabe salientar que o sistema imune biológico é capaz de iniciar a defesa contra qualquer tipo de agente patogênico, seja ele pré-existente ou não.

Alguns conceitos básicos que fazem parte do sistema imunológico biológico, segundo De Castro (2001) são:

- **Imunologia:** ramo da biologia responsável pelo estudo das reações de defesa que conferem resistência às doenças;

- **Sistema Imunológico:** sistema que defende o animal contra o ataque constante de microorganismos;
- **Patógenos:** agentes causadores de patologia ou enfermidade (por exemplo vírus, bactérias, fungos e parasitas);
- **Antígenos:** moléculas capazes de serem reconhecidas pelo sistema imunológico;
- **Anticorpos:** moléculas receptoras de antígeno expressas nas superfícies de algumas células do sistema imune.

O sistema imunológico é parte fundamental para a sobrevivência dos seres humanos, sendo assim, necessita ser muito eficiente na sua atuação. Existe uma grande quantidade de componentes e mecanismos diferentes atuando no sistema imunológico. Alguns destes elementos são otimizados para defender o organismo contra um único invasor enquanto outros são direcionados contra uma grande variedade de agentes infecciosos (De Castro, 2001).

O sistema imunológico é de grande eficiência no combate a microorganismos invasores. Ele também é responsável pela limpeza do organismo, ou seja, a retirada de células mortas, a renovação de determinadas estruturas, rejeição de enxertos e memória imunológica. Além disso, o SI é ativo também contra células alteradas, que diariamente surgem no nosso organismo, como resultado de mitoses anormais. Essas células, se não forem destruídas, podem dar origem a tumores.

O complexo funcionamento do Sistema Imune é composto por diversos princípios (mecanismos) que possuem características particulares. Alguns desses princípios servem de base para a construção de Sistemas Imunes Artificiais. Os mais relevantes são apresentados a seguir.

### 2.1.1 Princípio da Seleção Clonal

O princípio (ou teoria) da seleção (ou expansão) clonal assume que, quando o organismo é invadido por antígenos, as células do SI (iremos tratar neste trabalho somente células B<sup>1</sup>) que re-

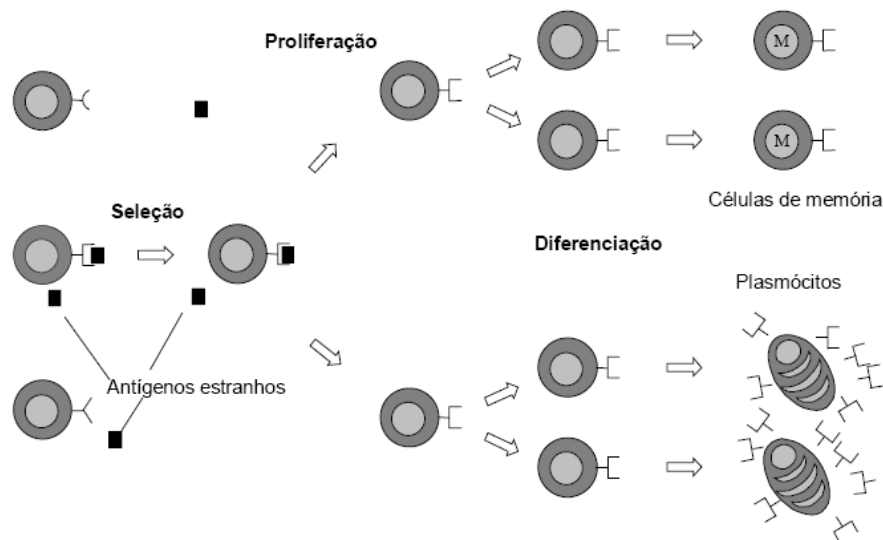
---

<sup>1</sup>Pequenas células brancas cruciais para as defesas imunes produzidas na medula óssea e diferenciam-se em plasmócitos, geradoras dos anticorpos, ou células de memória, capazes de responder rápida e efetivamente contra



conhecem o antígeno se reproduzem, gerando novas células sendo estas denominadas de clones. O que define a quantidade de clones que cada célula irá gerar é a afinidade entre cada anticorpo e o antígeno invasor, ou seja, quanto maior a afinidade entre eles, maior o número de clones gerados. Durante a proliferação, os clones são submetidos a um processo de mutação a taxas inversamente proporcionais à afinidade entre o clone e o antígeno; quanto maior a afinidade, menor a taxa de mutação e vice-versa. Os clones, então mutados, que possuem elevada afinidade em relação ao antígeno são selecionados via processo de seleção natural. Esses clones selecionados irão ser diferenciados em dois grupos de células: células que excretam anticorpos que irão atuar contra o antígeno invasor (plasmócitos), eliminando-o, e células de memória que permanecerão no organismo para atuar eficiente e rapidamente em futuras invasões do mesmo antígeno ou de antígenos semelhantes (GOMES, 2006).

O comportamento básico desse princípio pode ser visto na Figura 1.



**Figura 1: Princípio da Seleção Clonal**

**Fonte: De Castro (2001).**


A Teoria da Seleção Clonal sugere que entre todas as células possíveis, com diferentes re-infecções.

receptores circulando no organismo, aquela realmente capaz de identificar o antígeno, inicie a proliferação pela clonagem. A partir daí, quando uma célula B é ativada pela ligação com um antígeno, isto produz muitos clones em um processo chamado expansão clonal. As células resultantes podem passar pela hipermutação somática, criando células filhas com os receptores mutados. Os anticorpos competem no processo de identificação com essas novas células B, com seus pais e com outros clones. Isto resulta em um processo darwiniano de variação e seleção, chamado de maturação da afinidade. O aumento de tamanho dessas populações e a produção de células com esperado longo ciclo de vida asseguram ao organismo uma resposta positiva a um ataque por antígeno, criando uma defesa por longo tempo (memória imunológica). A teoria da seleção clonal está associada às características básicas de uma resposta imune adaptativa a um estímulo antigênico. Ela estabelece que apenas aquela célula capaz de reconhecer um determinado estímulo antigênico irá se proliferar, sendo, portanto, selecionada em detrimento das outras (ANILE et al., 2007) (De Castro, 2001).

### 2.1.2 Teoria da Rede Imunológica

A teoria da Rede Imunológica propõe que as células imunológicas, além de reconhecerem antígenos, são capazes de reconhecer outras células imunológicas. Assim, o sistema imunológico pode gerar uma resposta devido à interação de células imunológicas. O Sistema Imunológico mantém dinamicamente e de forma ótima o repertório de anticorpos no organismo. Para isso, ele faz uso de um mecanismo de supressão das células redundantes (que possuem grande afinidade entre si) do organismo, além da seleção de novas células de memória (GOMES, 2006).

A dinâmica desse mecanismo é apresentada na Figura 2. A figura 2 ilustra três anticorpos interagindo entre si, gerando uma resposta negativa, o que leva ao processo de supressão e um anticorpo (anticorpo número 1) interagindo com um antígeno (Ag), gerando uma resposta positiva que ativa aquele anticorpo para eliminar aquele antígeno.



**Figura 2: Princípio da Rede Imunológica.**

**Fonte: De Castro (2001).**

### 2.1.3 Recombinação Gênica

A recombinação gênica tem por finalidade gerar moléculas de anticorpos através de bibliotecas gênicas, ou seja, gerar novos indivíduos a partir de recombinação de alguns fragmentos de genes armazenados nessas bibliotecas. Todas as células sanguíneas, incluindo as células imunológicas, são geradas na medula óssea, onde vários genes provenientes de diversas bibliotecas gênicas são concatenados de forma a produzir uma única célula (GOMES, 2006).

## 2.2 CLONALG

O Algoritmo de Seleção Clonal (*Clonal Selection Algorithm*) é baseado na Teoria de Seleção Clonal natural, fazendo uma analogia específica nos elementos da geração e proliferação de clones, na presença de antígenos e na modificação dos clones através da aplicação da hipermutação (ALMEIDA, 2007). O Clonalg foi originalmente desenvolvido por De Castro e Zuben (2001).

O Algoritmo 1 apresenta o funcionamento básico de um Clonalg padrão. O Clonalg trabalha com uma população de soluções candidatas (anticorpos<sup>2</sup>), composta por um subconjunto de

<sup>2</sup>Não são feitas distinções entre células B e anticorpos.

---

**Algoritmo 1** Algoritmo do Clonalg Padrão

---

**Clonalg Original**

Inicie a População;

Avalie a População;

**Enquanto o critério de término não for satisfeito**

Clone a população;

Aplique a hipermutação;

Avalie os Clones;

Aplique o operador de Seleção (substitui piores anticorpos por novos anticorpos);

**Fim Enquanto**

---

células de memória (melhores anticorpos) e um outro subconjunto de bons indivíduos. Em cada geração um conjunto de melhores indivíduos na população é selecionado baseado na afinidade<sup>3</sup> dos mesmos em relação aos antígenos.

Os indivíduos selecionados são clonados, elevando temporariamente a população dos clones. Os operadores de clonagem mais comuns são: operador de clonagem estático, onde o número de clones de cada anticorpo é *dup*<sup>4</sup>, independente da afinidade do anticorpo e o operador de clonagem proporcional, onde o número de clones de cada anticorpo é proporcional à afinidade - quanto melhor afinidade, maior o número de clones. Os clones são então submetidos a um operador de hipermutação, com taxa proporcional (ou inversamente proporcional) à afinidade (entre o anticorpo e o antígeno. A partir desse processo uma população de anticorpos amadurecida é gerada. Alguns indivíduos dessa população temporária são selecionados para serem células de memórias ou para serem parte da próxima população. Todo esse processo é repetido até o momento que a condição de término seja satisfeita.

Com o decorrer dos anos, novas propostas (modificações) do algoritmo Clonalg têm surgido na literatura. Junto com essas modificações, novos problemas foram tratados utilizando-se de SIA (o Clonalg foi proposto inicialmente para solucionar problemas de aprendizado de máquina e reconhecimento de padrões (De Castro, 2001)). No trabalho de Almeida (2007) foi feito um estudo aprofundado sobre aplicações utilizando Sistemas Imunológicos Artificiais e serão resumidos nos tópicos a seguir juntamente com recentes trabalhos.

---

<sup>3</sup>Que pode ser medida pela qualidade da solução codificada no anticorpo.

<sup>4</sup>Um valor fixo durante todo o processo evolutivo

- **Busca e Otimização:** são problemas que consistem na determinação de uma solução ótima dentro de um espaço de busca. Exemplos de uso de SIA são encontrados em: (FRANÇA; Von Zuben; De Castro, 2005), (COELLO; CORTÉS, 2005), (WALKER; GARRETT, 2003), (CUTELLO; NICOSIA; PAVONE, 2003), (COSTA et al., 2002) e (HONÓRIO; SILVA; BARBOSA, 2007). Em França, Von Zuben e De Castro (2005) é proposta uma rede imune que estende a rede opt-aiNet (rede imune desenvolvida para problemas de otimização - (CASTRO; TIMMIS, 2002)) para utilização em ambientes dinâmicos. Esta rede foi denominada dopt-aiNet. A dopt-aiNet possui algumas características relevantes como ajuste automático do limiar de supressão e da taxa de mutação e novos tipos de mutação e, foi aplicada a problemas de otimização estáticos e dinâmicos obtendo bons resultados. Uma alternativa para a solução de problemas multi-objetivos com ou sem restrições é proposta em Coello e Cortés (2005). Neste trabalho um algoritmo baseado no princípio da seleção clonal, fazendo uso de memória secundária e função de aptidão baseada na dominância dos anticorpos é aplicado a funções clássicas de *benchmarks*. O problema de coloração de grafos é resolvido por um algoritmo imune baseado no princípio da seleção clonal que incorpora um processo de busca local em Cutello, Nicosia e Pavone (2003). Em Gonçalves et al. (2007), um algoritmo baseado em SIA é utilizado na solução do problema do despacho econômico e comparado com sua versão aculturada (acrescida de um algoritmo cultural guiando a busca). Em Vanaja, Hemamalini e Simon (2008), um algoritmo baseado em seleção clonal também é avaliado no problema do despacho econômico;
- **Mineração de Dados:** é o processo de análise sobre grandes conjuntos de dados que tem por objetivo a descoberta de padrões interessantes e que possam representar informações úteis. Existem diversos SIAs desenvolvidos para tratar este problema. Em Alves et al. (2004a) é proposto um novo algoritmo de indução de regras de classificação em mineração de dados, chamado IFRAIS. O IFRAIS busca descobrir um conjunto de regras *fuzzy*, através de um processo evolucionário baseado em SIA e procedimentos usuais em mineração de dados. O trabalho reporta resultados para várias bases de dados, alcançando resultados comparáveis a populares algoritmos para mineração de dados. Um algoritmo baseado nas metáforas de seleção negativa e seleção clonal é proposto em Lee et

al. (2003) para consultas adaptativas em *web* semântica. O trabalho de Alves et al. (2007) apresenta um SIA para descobrir um conjunto de regras para problemas de classificação hierárquica e multi-camadas. Neste sentido, uma simples regra de classificação pode determinar várias classes (camadas) em diferentes níveis da hierárquicos;

- **Predição da Estrutura e Função de Proteínas:** O algoritmo Clonalg (CUTELLO; NICOSIA; PAVONE, 2004) foi aplicado ao PPEP no modelo 2D HP. Em Cutello et al. (2005) e Cutello et al. (2006) o algoritmo Clonalg, usando operador de aging puro, foi aplicado ao problema da predição de proteínas nos modelos 2D e 3D HP. Modelos baseados no algoritmo Clonalg trabalhando em representações livres de *lattice* foram utilizados nos trabalhos de Cutello, Narzisi e Nicosia (2006) e Anile A. M. Cutello et al. (2006). O primeiro trabalho trata o PPEP como sendo um problema de otimização multi-modal, enquanto o segundo trata o problema como sendo multi-objetivo. Os dois utilizam o CHARMM<sup>5</sup> (MACKERELL et al., 1998) como função de energia a ser minimizada; em Almeida, Gonçalves e Delgado (2007) são apresentados algoritmos híbridos baseados em SIA, sistemas de inferência *fuzzy* e busca tabu para solucionar o problema de dobramento de proteína no modelo 3D hidrofóbico polar; os resultados obtidos atestam a eficiência da metodologia. O trabalho desenvolvido em Alves, Delgado e Freitas (2008) apresenta um algoritmo inspirado em SIA aplicado à predição de funções de proteína na ontologia gênica. Este é um problema extremamente complexo por se tratar de um problema de classificação hierárquica de múltiplos rótulos com uma grande quantidade de classes;
- **Aprendizagem de Máquina:** é o estudo de algoritmos que permitem a uma máquina aprender. Nos seguintes trabalhos dessa área foram utilizados SIA: (WATKINS; TIMMIS; BOGGESS, 2004) e (BERSINI, 1999). Um algoritmo para classificação que faz uso do princípio da seleção clonal e ARB (*antigenic recognition ball*) é proposto em Watkins, Timmis e Boggess (2004). Os ARBs são utilizados para restringir a proliferação de anticorpos redundantes;
- **Robótica:** problemas encontrados ou decorrentes da construção de robôs. Algumas

---

<sup>5</sup>CHARMM(*Chemistry at HARvard Macromolecular Mechanics*) é um programa para simulações de macromoléculas, incluindo minimização de energia, dinâmica molecular e simulações de Monte Carlo

aplicações de SIA para esse problema podem ser encontradas nos trabalhos: (ISHIGURO et al., 1998), (CANHAM; JACKSON; TYRRELL, 2003), (LAU; KO, 2007) e (VARGAS et al., 2003). Ishiguro et al. (1998) propuseram um SIA baseado no princípio de moderacionismo para controlar a movimentação de um robô com seis pernas. Uma rede imuno-genética para a movimentação autônoma de um robô do tipo Khepera II é proposta em Vargas et al. (2003). Nesta rede o sistema imune implementa o processo de decisão enquanto o algoritmo evolutivo define a estrutura da rede. Lau e Ko (2007) introduzem um SIA para controle de um sistema robótico de baixo custo baseado no mecanismo de supressão dos sistemas imunes;

- **Controle:** criação de sistemas que automatizam o controle de máquinas e processos quer sejam industriais ou não. Aplicações de SIA nessa área foram desenvolvidas em: (DING; REN, 2000), (KIM, 2001) e (LAW; WONG, 2004). Um controle *fuzzy* auto ajustável inspirado no mecanismo de *feedback* do sistema imune é proposto em Ding e Ren (2000) para controlar a temperatura da pele de pessoas com hipertermia. Em Kim (2001) é proposta uma rede imune para ajustar os parâmetros de um controlador PID;
- **Segurança Computacional e de Rede:** visa identificar e tratar possíveis invasores nos sistemas computacionais. Nos seguintes trabalhos dessa área foram utilizados SIAs: (De Paula; De Castro; GEUS, 2004), (WANG; HIRSBRUNNER, 2002), (MAZHAR; FAROOQ, 2007), (HAAG et al., 2007) e (ANCHOR et al., 2002). Um algoritmo baseado no princípio da seleção positiva que identifica possíveis ataques a uma rede de computadores é proposto em Anchor et al. (2002). É proposto em Mazhar e Farooq (2007) um SIA para a segurança de redes móveis Adhoc (MANETs) que detecta o mau funcionamento em um protocolo de roteamento bioinspirado (BeeAdhoc). Um sistema que faz uso de princípios do sistema imune inato, da teoria do perigo, da seleção e seleção negativa é proposto em De Paula, De Castro e Geus (2004) para identificar ataques de *buffer overflow*. Um SIA com um algoritmo evolucionário multiobjetivo para a detecção de intrusos em redes de computadores distribuídas é proposto em Haag et al. (2007);
- **Detecção de Falhas e Anomalias:** visa identificar possíveis invasores em sistemas computacionais e defeitos em qualquer tipo de sistema. O uso de sistemas imunológicos ar-

tificiais para a solução deste tipo de problema é abordado em: (BRADLEY; TYRRELL, 2000), (LEE et al., 2005), (GONZÁLEZ; DASGUPTA, 2003), (SHAFIQ; FAROOQ, 2007) e (GREENSMITH; AICKELIN; TWYXCROSS, 2004). Um *framework* de segurança que previne uma série de ataques DOS *Denial of Service* em redes 802.11b é proposto em Shafiq e Farooq (2007). Em Lee et al. (2005) a detecção de falha num contador é resolvido pelo uso de um sistema imune com ênfase na diversidade populacional, a qual é evoluída por evolução simbiótica. A detecção de intrusos é tratada através dos princípios da teoria do perigo em Greensmith, Aickelin e Twycross (2004).

Nesta dissertação, será avaliado o uso do algoritmo Clonalg como Espaço Populacional de um Algoritmo Cultural para solucionar problemas de Despacho Econômico. Os trabalhos correlatos são discutidos no capítulo 5. A implementação da metodologia proposta é descrita no capítulo 6.



### 3 ALGORITMOS CULTURAIS

As pesquisas mostram que melhorias consideráveis no desempenho dos algoritmos evolucionários podem ser alcançadas quando conhecimentos específicos do problema são utilizados para adaptar o processo de evolução, tendo em vista identificar padrões de desempenho no ambiente (SALEEM, 2001).

Nas sociedades humanas, a cultura pode ser vista como um veículo para o armazenamento de informações que são globalmente acessíveis à todos os membros da sociedade e que podem ser úteis, como guias, nas atividades de busca por soluções de problemas (COELHO; ALMEIRA; MARIANI, 2008) (REYNOLDS; ZHU, 2001).

Os Algoritmos Culturais (AC) foram inicialmente desenvolvidos por Robert G. Reynolds e são uma poderosa ferramenta para resolver problemas de busca e otimização. Assim como Algoritmos Genéticos, Evolução Diferencial, Sistemas Imunológicos Artificiais dentre outros, os AC são considerados métodos da computação evolucionária (SALEEM, 2001). São algoritmos baseados na evolução cultural da humanidade.

Durante a evolução dos indivíduos podem existir várias autoadaptações, pois cada vez que um conhecimento é adquirido, ele poderá ser utilizado em uma nova geração procurando influenciar novos indivíduos.

Os AC são sistemas de herança dupla, provendo a interação e cooperação mútua entre dois níveis distintos de evolução: espaço populacional e espaço de crença. Ou seja, AC são sistemas híbridos, sendo um algoritmo evolucionário (espaço populacional) e um AC puro (espaço de crenças). As funções de aceitação e influência provêm um mecanismo que permite a dualidade.

Segundo Saleem (2001), existem cinco tipos de conhecimentos os quais acredita-se ser possível representarem qualquer conhecimento social com a combinação de alguns desses. São eles: Conhecimento Situacional, Conhecimento Normativo, Conhecimento de Domínio, Conhecimento Topográfico e Conhecimento Histórico.

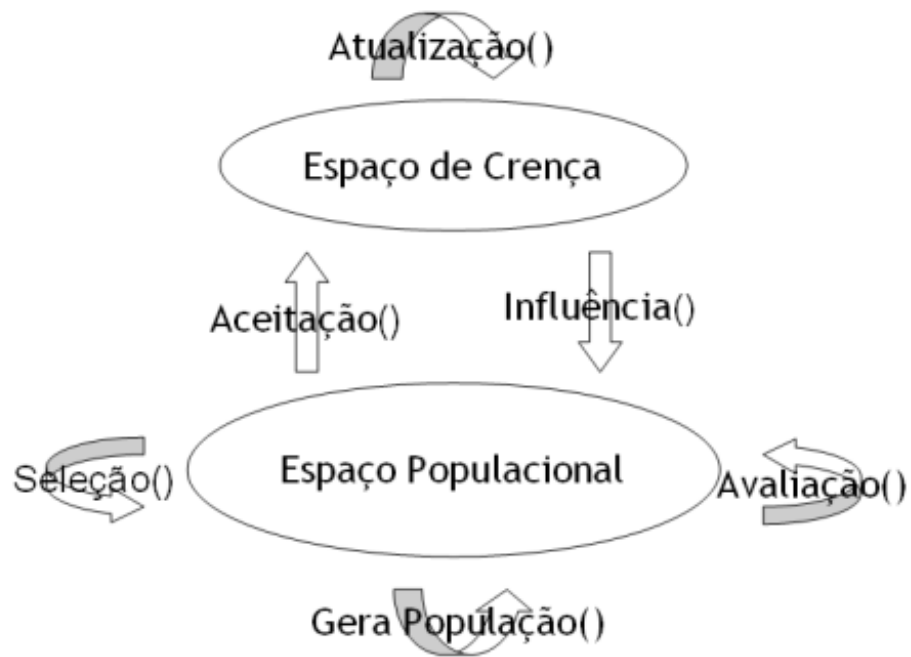
Algumas características dos AC são Reynolds (2003):

- Herança Dupla (herança em nível de conhecimento e população);
- O conhecimento guia a evolução da população;
- Suporte a hierarquização do espaço populacional e de crenças;
- Domínio do conhecimento separado do indivíduo;
- Suporte a autoadaptação em vários níveis;
- Evolução ocorre em diferentes taxas e níveis (cultura evolui mais rapidamente que um elemento biológico);
- Diferentes abordagens (sistema híbrido) na solução de problemas;
- Plataforma computacional no qual muitos dos mais variados modelos de mudança cultural podem ser expressos.

### 3.1 MODELO BÁSICO DE ALGORITMOS CULTURAIS

A Figura 3 apresenta o ciclo básico de operações de um Algoritmo Cultural. Abaixo são resumidas as funções principais.

- Espaço Populacional: qualquer algoritmo evolucionário que possua uma população de indivíduos;
- Função Gera População: gera os primeiros indivíduos da população;
- Função Avaliação: avalia os indivíduos, para saber qual a qualidade dos mesmos;



**Figura 3: Ciclo Básico do Algoritmo Cultural**

**Fonte: Adaptado de Reynolds e Ali (2008).**

- Função Seleção: seleciona os indivíduos baseado em determinadas regras;
- Espaço de Crenças: local onde são armazenados os conhecimentos adquiridos;
- Função de Aceitação: seleciona quais conhecimentos dos indivíduos podem fazer parte do espaço de crenças;
- Função de Atualização: função que atualiza os conhecimentos, eliminando ou acoplando conhecimento;
- Função de Influência: função que influencia a nova geração de indivíduos, buscando que os mesmos sejam influenciados pelos conhecimentos.

Uma outra forma de se observar o funcionamento básico de um Algoritmo Cultural é através do pseudocódigo do Algoritmo 2.

---

**Algoritmo 2** Forma Básica de um Algoritmo Cultural (REYNOLDS, 2003)

---

**Algoritmo Cultural**

Inicie a População;

Inicie o Espaço de Crenças;

**Repita**

    Avalie a População;

    Atualize o Espaço de Crenças através da Função de Aceitação;

    Gere a Próxima População a partir da Atual considerando a Função de Influência;

**Até que a Condição de Término seja Satisfeita**

---

Primeiramente são feitas as inicializações do Espaço Populacional (gerada a população de indivíduos) e o Espaço de Crenças. Então o algoritmo entra no laço principal onde serão realizadas a avaliação da população, a atualização do Espaço de Crença por meio da Função de Aceitação (os melhores indivíduos são selecionados e adicionados ao Espaço de Crença) e então é gerada a nova população de indivíduos influenciada pelos conhecimentos adquiridos (através da Função de Aceitação). Todo processo é repetido até que a condição de parada do laço seja alcançada.

Nos próximos tópicos serão abordadas todas as etapas detalhadamente.

## 3.2 ESPAÇO POPULACIONAL E ESPAÇO DE CRENÇAS

Um Algoritmo Cultural implementa dois componentes independentes mas conectados entre si: Espaço Populacional e Espaço de Crenças. Essa conexão o torna um algoritmo de herança dupla (ou herança dual), pois herda características de dois componentes diferentes.

### 3.2.1 Espaço Populacional

O Espaço Populacional armazena a população de indivíduos. O Espaço Populacional pode ser representado por qualquer algoritmo evolucionário. O Espaço Populacional engloba um conjunto de possíveis soluções para o problema, e pode ser modelado utilizando qualquer abordagem baseada em população (LIN; CHEN; LIN, 2009).

Existem muitos algoritmos que podem ser utilizados no Espaço Populacional, alguns deles serão brevemente explicados nos itens a seguir.

- **Evolução Diferencial (*Differential Evolution*):** A proposta do algoritmo evolutivo de Evolução Diferencial ( ED) foi originalmente formulada por Storn e Price (1995), e surgiu de tentativas de resolver o problema de ajuste polinomial de Chebychev. É um algoritmo evolucionário aplicado em problemas de busca e otimização. Kenneth Price introduziu a idéia de usar diferenças de vetores para perturbar a população de vetores (indivíduos) resultando em um método que requer poucas variáveis de controle, é de rápida convergência, fácil de usar e robusto (ARANTES; OLIVEIRA; SARAMAGO, 2006) (OLIVEIRA, 2006);
- **Algoritmos Genéticos (*Genetic Algorithm*):** Os Algoritmos Genéticos ( AG) foram originalmente desenvolvidos por John Holland e alguns de seus colaboradores (HOLLAND, 1962). Os AG são algoritmos estocásticos de busca inspirados no comportamento das espécies na natureza. Os AG tratam basicamente da simulação da evolução de estruturas individuais (cromossomos), via processo de seleção e os operadores de busca, chamados operadores genéticos (mutação e cruzamento). O motivo da inspiração na natureza

é que esta consegue resolver satisfatoriamente problemas altamente complexos (como a sobrevivência das espécies, por exemplo) (GOLDBERG, 1989) (RODRIGUES, 2007);

- **Programação Genética (*Genetic Programming*):** O algoritmo de Programação Genética ( PG) foi originalmente apresentado por Koza (1990) e é um algoritmo evolucionário inspirado na teoria evolucionista de Darwin e fundamentos da biologia (molecular) e da evolução natural. A PG é a evolução de programas de computador usando analogias com muitos dos mecanismos utilizados pela evolução biológica natural. A implementação de PG é conceitualmente imediata quando associada a linguagens de programação que permitem a manipulação de um programa computacional na forma de uma estrutura de dados, inclusive por possibilitar que novos dados do mesmo tipo e recém-criados sejam imediatamente executados como programas computacionais. A programação genética pode se constituir em uma opção especialmente interessante para o caso de programação de computadores com processamento paralelo (GUDWIN; ZUBEN, 1998) (WALKER; MILLER, 2008);
- **Nuvem de Partículas (*Particle Swarm Optimization*):** O algoritmo de Nuvem ou Enxame de Partículas ( NP) foi proposta originalmente por Eberhart e Kennedy (1995). NP é uma técnica de busca heurística que simula o comportamento social (movimentos) de bando de pássaros em revoada ou cardume de peixes. Embora a NP tenha sido originalmente adotada para equilíbrio de “pesos” em redes neurais, rapidamente se tornou um popular otimizador global, principalmente em problemas em que as variáveis de decisão são números reais. (REYES-SIERRA; COELLO, 2006);
- **Colônia de Formigas (*Ant Colony Optimization*):** Colônia de Formigas é uma meta-heurística proposta para solucionar problemas combinatoriais de otimização difíceis. Originalmente desenvolvido por Marco Dorigo, a fonte de inspiração são as colônias de formigas naturais, as quais utilizam rastros de feromônio como forma de comunicação (DORIGO; MANIEZZO; COLORNI, 1991). Um importante e interessante comportamento das colônias de formigas, em particular, é como as formigas descobrem os caminhos mais curtos entre as fontes de alimentos e o ninho. Colônia de Formigas têm sido aplicadas com sucesso na área de redes de computadores, em especial em problemas de

roteamento (DORIGO; STUTZLE, 2003) (WANG; LIU, 2006);

- **Sistema Imunológico Artificial (*Artificial Immune System*):** Os Sistemas Imunológicos Artificiais se inspiram no funcionamento do Sistema Imune para a solução de diversos problemas e existem vários modelos de Sistemas Imunológicos Artificiais. Neste trabalho será utilizado um AC cujo Espaço Populacional é representado por um Sistema Imunológico Artificial baseado na Teoria da Seleção Clonal (Clonalg). Detalhes podem ser encontrados no Capítulo 2.

### 3.2.2 Espaço de Crenças

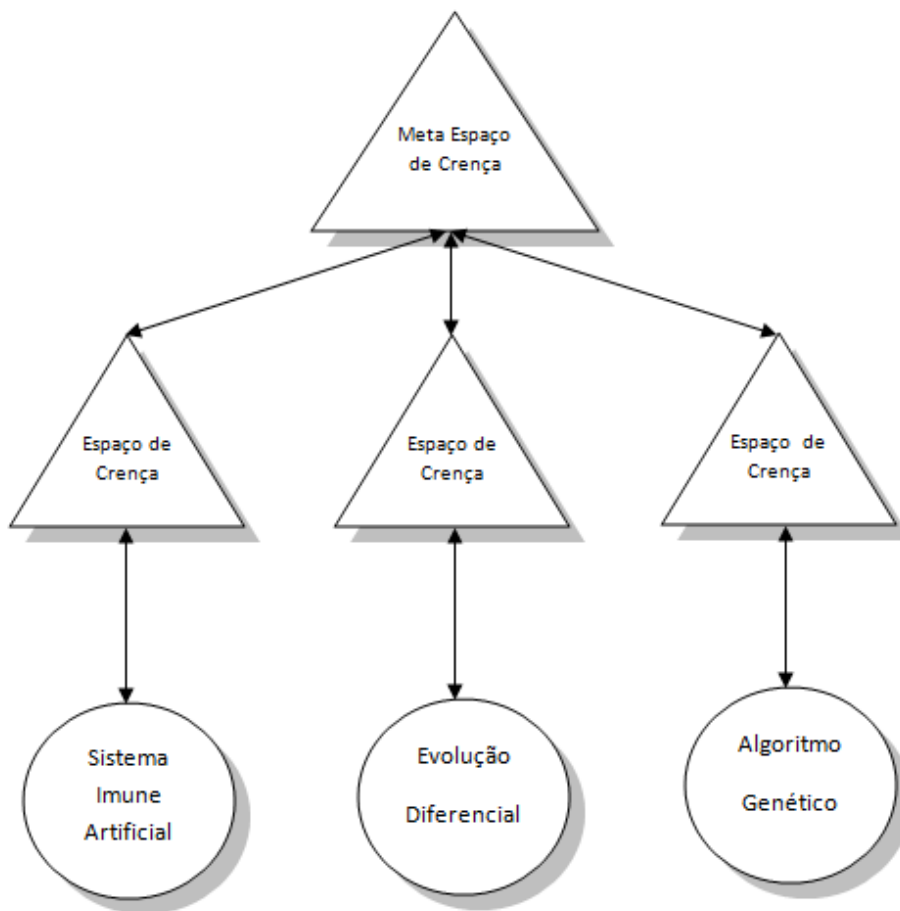
O Espaço de Crenças é o local onde são armazenados os conhecimentos adquiridos dos indivíduos durante o processo de evolução. Sendo assim, caso um indivíduo seja removido da população, o seu conhecimento estará armazenado e possivelmente utilizado.

O Espaço de Crenças é o repositório de informação onde os indivíduos podem armazenar suas experiências para que outros indivíduos aprendam a partir delas indiretamente. Em Algoritmos Culturais a informação adquirida por um indivíduo pode ser compartilhado com a população inteira, diferente da maioria das técnicas evolucionárias, onde a informação pode ser compartilhada apenas com os indivíduos que foram gerados (filhos) (LIN; CHEN; LIN, 2009).

Dentro do Espaço de Crenças existe uma função (Função de Atualização) que atualiza o Espaço toda vez que um novo conhecimento é aceito (através da Função de Aceitação), podendo adicionar o novo conhecimento ao Espaço e/ou remover algum conhecimento já não utilizado.

Os Algoritmos Culturais permitem ainda que haja um Metaespaço de Crenças que, da mesma forma que um Espaço de Crenças armazena conhecimentos de um Espaço Populacional, o Meta-espaço de Crenças armazena conhecimentos sobre outros Espaços de Crenças, trabalhando paralelamente com diferentes abordagens para solução de um mesmo problema. A Figura 4 apresenta esse conceito.

Se por um lado essa técnica de Multi-espaço de Crenças busca fornecer resultados ainda melhores, por outro lado ela apresenta extrema dificuldade na implementação (já que um único espaço de crenças já apresenta uma certa dificuldade em sua implementação).



**Figura 4: Exemplo de um Meta-espço de Crenças**

**Fonte: Adaptado de Reynolds (2003).**



Neste trabalho será utilizado apenas um Espaço de Crenças.

### 3.3 PROTOCOLOS DE COMUNICAÇÃO

Os protocolos de comunicação (representados pela Função de Aceitação e Influência) entre o Espaço Populacional e o de Crença possuem influência no processo evolutivo, pois são eles que manipulam os conhecimentos necessários e aplicam esses conhecimentos para que novos indivíduos sejam gerados com melhor qualidade.

A Função de Aceitação verifica quais características dos indivíduos podem contribuir para evolução da população e a Função de Influência faz com que a nova geração de indivíduos possa ser influenciada por essas características. Estas funções serão detalhadas a seguir.

#### 3.3.1 Função de Aceitação

A Função de Aceitação determina quais indivíduos e seus comportamentos podem ter impacto no Espaço de Crenças. Ela seleciona os indivíduos que pode impactar diretamente a formação do conhecimento armazenado no Espaço de Crenças (YUAN et al., 2008).

As Funções de Aceitação podem ser divididas em classes, que são:

- **Estática:** baseada em um ranqueamento, onde um determinado número de indivíduos é selecionado. O *ranking* pode ser absoluto, ou seja, uma certa porcentagem da população é escolhida, ou relativo, onde apenas os indivíduos acima de determinada média são selecionados;
- **Dinâmica:** durante o processo de evolução, o percentual de indivíduos escolhidos oscila; no início o processo é menos restrito (muitos conhecimentos são aceitos) e no decorrer da evolução se torna mais restrito (já se sabe quais conhecimentos realmente impactam o Espaço de Crença);
- **Fuzzy:** podem ser baseadas em variáveis linguísticas ou matrizes de pertinência. Em Reynolds e Chung (1997), por exemplo, por meio de um Sistema de Inferência *Fuzzy* os

indivíduos são selecionados baseados na convergência da população, onde quanto melhor a convergência maior o número de indivíduos aceitos; em Reynolds e Zhu (2001) são selecionados apenas os indivíduos semelhantes ao melhor indivíduo atual, através de uma Matriz de Similaridade *Fuzzy* e uma Matriz de  $\alpha$ -Cortes.

Neste trabalho será utilizado uma Função de Aceitação Dinâmica, conforme detalhado no Capítulo 6.

### 3.3.2 Função de Influência

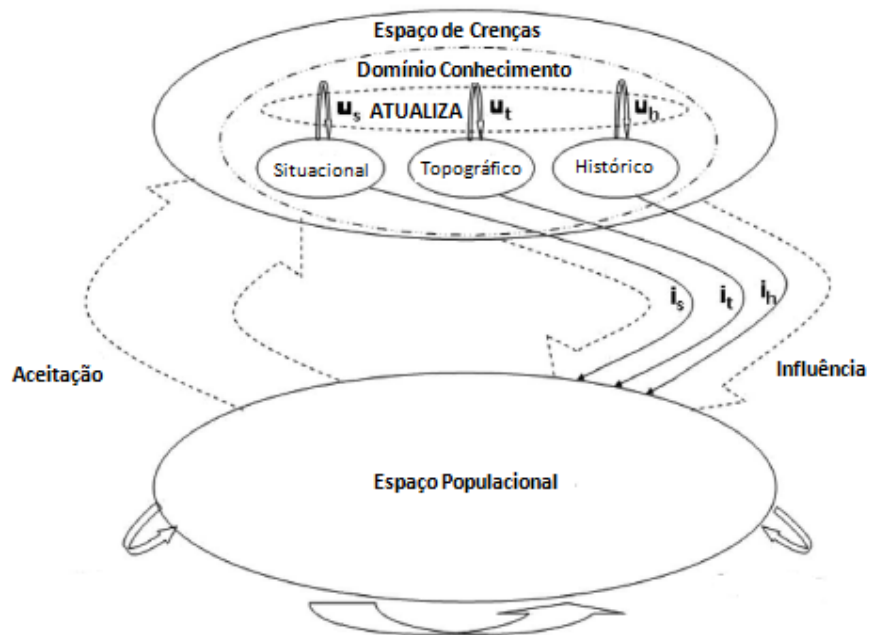
A Função de Influência determina como os conhecimentos podem ser úteis para formação de novos indivíduos. Normalmente é utilizada uma Função de Influência para cada tipo de conhecimento, a qual consiste em um operador modificado para utilizar o conhecimento em determinado momento.

Algumas Funções de Influência podem ser mais úteis que outras, dependendo do comportamento e conhecimento necessário, e elas podem ser utilizadas individualmente ou em conjunto (SALEEM, 2001).

As Funções de Influência podem ser vistas como formas de autoadaptação, pois elas se adaptam conforme os conhecimentos vão sendo adquiridos.

A Figura 3.3.2 ilustra o funcionamento dos protocolos de comunicação. A Função de Aceitação seleciona os indivíduos aptos a fazerem parte do Espaço de Crenças. A Função de Influência (principal) determina qual dos conhecimentos irá influenciar em determinado indivíduo; no exemplo da Figura 3.3.2 cada conhecimento tem sua função de influência, que será aplicada no momento em que for selecionada pela Função de Influência Principal. Nesse exemplo apenas três conhecimentos são apresentados, mas não existe uma regra que determine quantos e quais conhecimentos irão influenciar melhor ou pior, são necessários testes e pesquisa sobre o que já foi desenvolvido para determinar qual a melhor configuração para determinado problema.

Neste trabalho foi desenvolvida uma Função de Influência *Fuzzy* (detalhes ver Capítulo 6).



**Figura 5: Exemplo da representação dos protocolos que fazem a comunicação entre o Algoritmo Cultural e o Algoritmo Evolutivo**

**Fonte: Adaptado de Arpaia, Lucariello e Zanesco (2007).**

### 3.4 TIPOS DE CONHECIMENTOS


Segundo Saleem (2001), é possível representar qualquer conhecimento cultural com a combinação dos seguintes conhecimentos: conhecimento situacional, conhecimento normativo, conhecido de domínio, conhecimento topográfico e conhecimento histórico.

O conhecimento representado no Espaço de Crenças pode variar dependendo da natureza do problema e dos objetivos a serem alcançados. Por exemplo, em determinados problemas alguns tipos de conhecimentos podem não ser úteis.

#### 3.4.1 Conhecimento Situacional

O conhecimento situacional contém um conjunto de indivíduos da população, os quais servem de exemplo para o restante da população. O conhecimento situacional representa os melhores indivíduos da população durante a geração.

A estrutura do conhecimento situacional é representada por meio de uma lista de indivíduos exemplares, onde cada indivíduo ( $E$ ) contém uma valor para cada parâmetro ( $x_1, x_2, \dots, x_n$ ) e o  $f(x)$  (*fitness*, representando a qualidade do indivíduo na solução do problema em questão). A Fig. 6 ilustra a lista representado o conhecimento situacional.



**Figura 6: Exemplo da representação do Conhecimento Situacional**


**Fonte: Adaptado de Saleem (2001).**

A atualização do conhecimento situacional ocorre quando surge na população um indivíduo que possui um *fitness* superior ao *fitness* do pior indivíduo armazenado. Assim a função de aceitação incorpora este indivíduo e a atualização substitui o de pior *fitness* por este.

### 3.4.2 Conhecimento Normativo

O conhecimento normativo é representado por um conjunto de intervalos que caracterizam uma boa solução para cada parâmetro codificado. Esses intervalos provêm uma orientação para que os indivíduos tenham seus parâmetros ajustados dentro desse intervalo (ZHANG et al., 2008).

A estrutura do conhecimento normativo pode ser representada como na Fig. 7. Para cada característica ( $X_j$ ), são armazenados os valores mínimos ( $l_j$ ) e máximos ( $L_j$ ), e também os valores de desempenho (*fitness*) mínimo ( $f(l_j)$ ) e máximo ( $f(L_j)$ ).



**Figura 7: Exemplo da representação do Conhecimento Normativo**

**Fonte: Adaptado de Zhang et al. (2008).**

A atualização do conhecimento normativo pode ocorrer de duas maneiras: caso algum indivíduo aceito para o Espaço de Crenças apresente características que não se encontram dentro dos intervalos atuais, há uma expansão (apenas nos intervalos específicos onde houve a extrapolação); caso todos os indivíduos aceitos apresentem características pertencentes aos intervalos atuais há uma contração (nos intervalos específicos onde não houve a extrapolação) se, e somente se, a qualidade dos indivíduos aceitos for melhor do que dos indivíduos associados

aos extremos. Assim, na contração os extremos passam a ser definidos pelos indivíduos de melhor *fitness*.

### 3.4.3 Conhecimento de Domínio

O conhecimento de domínio consiste em conhecer o domínio do problema tratado. Ele representa conhecimento sobre o domínio do problema para guiar a busca de uma forma eficiente (RODRIGUES, 2007). O conhecimento de domínio é o menos utilizado, devido a sua dificuldade de abstração e representação.


### 3.4.4 Conhecimento Topográfico

O conhecimento topográfico tem por objetivo explorar e identificar regiões promissoras dentro do espaço de busca. Esse conhecimento faz que com novos indivíduos explorem regiões em busca de áreas que gerem resultados satisfatórios. Esse é o conhecimento que extrai padrões de comportamento do espaço de busca e explora diversas áreas do mesmo.

Existem algumas formas para representar o Conhecimento Topográfico. Um exemplo para se compreender o funcionamento do mesmo conforme apresentado na Figura 8, onde o conhecimento é representado por uma árvore binária (este foi o método escolhido na implementação do Conhecimento Topográfico dessa dissertação). No início, todo espaço de busca é representado apenas pelo nó raiz (no exemplo, o nó A), que armazena também o melhor indivíduo encontrado na região. Somente os nós folhas são armazenados, vistos que se observar pela figura, na mesclagem de todos os nós folhas (C, D, F e G) teremos o espaço de busca representado por inteiro .

A atualização do espaço de busca ocorre cada vez que um melhor indivíduo que o indivíduo atual na região é encontrado. No exemplo da Figura 8, a região é subdividida em duas e cada uma armazena um melhor indivíduo. Seguindo o exemplo pode-se observar na Figura 8 que existem quatro regiões e, nesse caso, existem quatro indivíduos exemplares (melhores indivíduos em cada região).

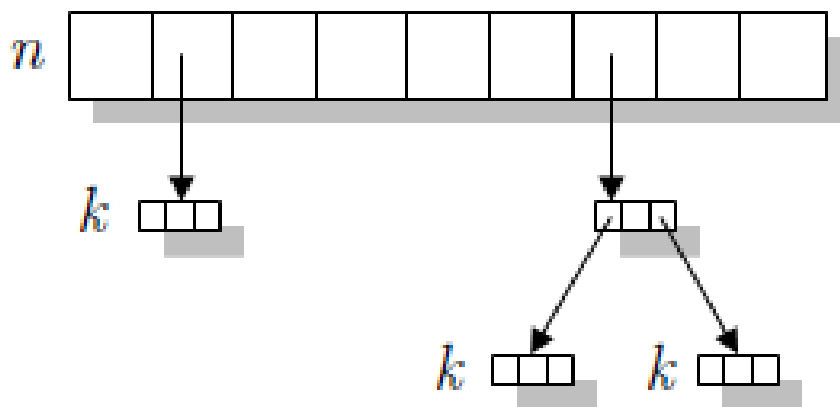
No trabalho de (SALEEM, 2001) a estrutura do conhecimento topográfico é representado



**Figura 8: Representação do Conhecimento Topográfico**

**Fonte: Adaptado de Becerra e Coello (2004).**

por um vetor de tamanho  $n$ , onde  $n$  é o número de células. Cada célula do vetor pode gerar uma lista com novas células, quando dividida em outras pequenas  $k$  células. Uma célula irá gerar um filho se o valor do *fitness* de um novo indivíduo aceito for melhor que o *fitness* do melhor indivíduo até então na célula. Esse modelo de representação do conhecimento pode ser observado na Figura 9.



**Figura 9: Representação do Conhecimento Topográfico**

Fonte: Adaptado de Saleem (2001).

### 3.4.5 Conhecimento Histórico

Esta fonte de Conhecimento foi introduzida em Algoritmos Culturais como uma forma de adaptar mudanças no ambiente (REYNOLDS; PENG, 2006).

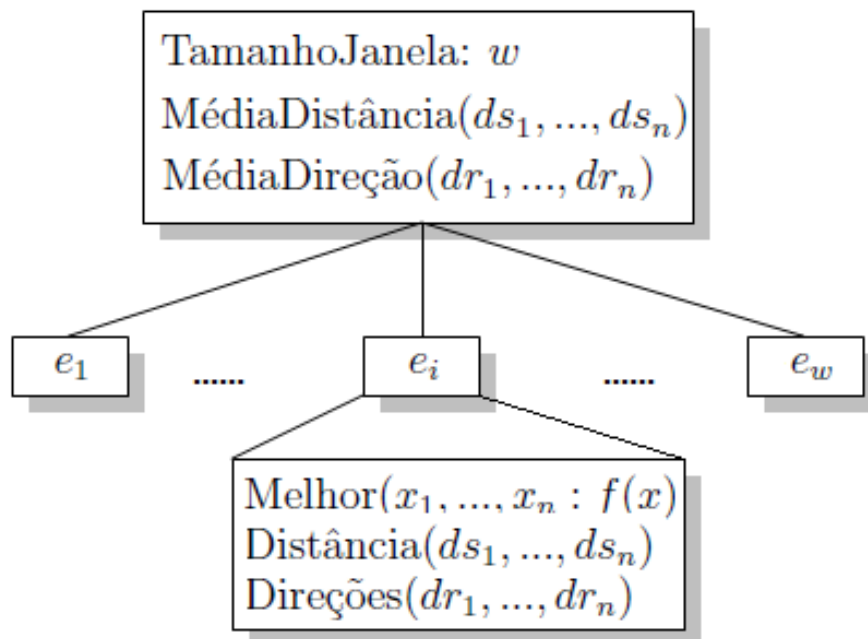
O conhecimento histórico contém informações sobre sequências de alterações em termos de distância e direção do valor ótimo dentro do espaço de busca ao longo das mudanças ambientais. Como o nome pressupõe, esse conhecimento armazena um histórico sobre eventos ocorridos durante o processo de evolução, fazendo com que os indivíduos possam consultar quais direções



seguir. Esse conhecimento retém eventos importantes da evolução.

O número de eventos armazenados no conhecimento histórico corresponde a um tamanho de janela ( $w$ ), que determina quantas mudanças podem ser guardadas numa lista em qualquer tempo. O conhecimento histórico contém uma média da distância e direção e uma lista de alterações em eventos.

A representação desse conhecimento pode ser vista na Figura 10, onde:  $w$  representa o tamanho da memória (número máximo de eventos representados),  $e_1$  até  $e_w$  são eventos representando as mudanças de ambiente, distância ( $ds_1$  até  $ds_n$ ) representa o vetor de distância tomada entre o indivíduo armazenado no evento atual e o indivíduo armazenado no evento anterior. O cálculo da distância pode ser observada na Equação 1.



**Figura 10: Representação do Conhecimento Histórico**

Fonte: Adaptado de Saleem (2001).

$$ds_j^i = \text{abs}(X_j^i - X_j^{i-1}) \quad (1)$$

De forma análoga é feito o cálculo para a direção, dada pela Equação 2.

$$dr_j^i = \text{sinal}(X_j^i - X_j^{i-1}) \quad (2)$$

As médias calculadas ao longo da história são dadas pelas Equações 3 e 4, para distância e direção respectivamente.

$$\text{Media}(ds_j) = (\sum_{i=2}^w ds_j^i) / (w - 1) \quad (3)$$

$$\text{Media}(dr_j) = (\sum_{i=2}^w dr_j^i) / (w - 1) \quad (4)$$

Os conhecimentos utilizados neste trabalho (Situacional, Normativo, Topográfico e Histórico) serão adaptados ao contexto do problema tratado e os detalhes são fornecidos no Capítulo 6.

#### 4 SISTEMA DE INFERÊNCIA FUZZY

Os Sistemas de Inferência *Fuzzy* (SIF) são modelos computacionais baseados em três conceitos principais: teoria de conjuntos *fuzzy*, regras *fuzzy* e raciocínio *fuzzy* (PEDRYCZ; GOMIDE, 2007).

A teoria de conjuntos *fuzzy* foi proposta por Lofti Zadeh (ZADEH, 1965) com o objetivo de fornecer uma ferramenta matemática para o tratamento de informações imprecisas ou vagas. Os conjuntos *fuzzy* formam a base teórica para o entendimento dos SIF (PEDRYCZ; GOMIDE, 1998).

As regras *fuzzy* relacionam as variáveis de entrada às variáveis de saída através da combinação de termos linguísticos os quais dão significado semântico aos conjuntos *fuzzy* representados por suas respectivas funções de pertinência.

O raciocínio *fuzzy* é o mecanismo básico que permite inferir uma saída a partir de um fato e de uma ou mais regras *fuzzy*.

Segundo Jang, Sun e Mizutani (1997), um Sistema de Inferência *Fuzzy* possui uma estrutura básica formada por três componentes conceituais:

1. **Base de dados:** define as funções de pertinência que serão utilizadas nas regras *fuzzy*;
2. **Base de Regras:** especifica o número de regras e como os termos linguísticos são combinados em cada regra;
3. **Mecanismo de raciocínio:** procedimento de inferência sobre as regras e fatos para gerar saídas (ou conclusões) adequadas.

Conforme discutido em Jang, Sun e Mizutani (1997), Pedrycz e Gomide (2007), os SIF têm sido aplicados com sucesso em muitas áreas, dentre elas destacam-se: controle automático, classificação e reconhecimento de padrões, tomada de decisão, sistemas inteligentes, previsão de séries temporais e robótica.

#### 4.1 INTRODUÇÃO AOS CONJUNTOS *FUZZY*

Conceitualmente, conjuntos *fuzzy* constituem uma das principais e fundamentais noções em Ciência e Engenharia. Há uma série de exemplos nos quais é possível encontrar elementos cujo enquadramento em um determinado conceito (ou classe) pode ser satisfeito por um certo grau. Pode-se ainda justificar a afirmação acima considerando o fato de que a continuidade da transição entre a pertinência completa e a exclusão completa é uma característica importantíssima no mundo físico e nos sistemas naturais. Por exemplo, pode-se classificar um ambiente interno como confortável quando a temperatura é mantida em  $20^{\circ}\text{C}$ . Se no entanto a temperatura for alterada para  $20,5^{\circ}\text{C}$  ou  $19,5^{\circ}\text{C}$  a sensação de conforto permanece a mesma para um observador humano. Assim o valor  $20^{\circ}\text{C}$  é completamente compatível com o conceito de *ambiente confortável* e só deixaria de ser ao atingir, por exemplo, valores como  $0^{\circ}\text{C}$  ou  $30^{\circ}\text{C}$ . Estes dois últimos valores seriam mais compatíveis com os conceitos *ambiente frio* e *ambiente quente*, respectivamente (PEDRYCZ; GOMIDE, 2007).

Considerando  $\mathbf{X}$  uma coleção de objetos denominados genericamente por  $x$ . Então, um conjunto  $A$  pode ser definido por uma coleção de pares ordenados

$$A = \{(x, \mu_A(x)) \mid x \in \mathbf{X}\} .$$

A função  $\mu_A(x)$  é dita função de pertinência e determina com que grau um objeto  $x$  pertence a um conjunto  $A$ , e  $\mathbf{X}$  é chamado de universo. Em conjuntos clássicos (crisp), somente dois valores para  $\mu_A(x)$  são permitidos, pois o elemento pertence ou não pertence a determinado conjunto. Já na teoria dos conjuntos *fuzzy* a transição entre pertencer e não pertencer é gradual (DELGADO, 2002).

Por exemplo: considere uma coleção de números inteiros  $\mathbf{X} = \{1, 2, 3, 4, 5, 6, 7, 8, 9\}$ . Seja  $A$  um conjunto *fuzzy* que define “números inteiros próximos a 5”, dado por

$$A = \{(1, 0), (2, 0.4), (3, 0.6), (4, 0.8), (5, 1), (6, 0.8), (7, 0.6), (8, 0.4), (9, 0)\}.$$

Sendo assim, o conjunto *fuzzy*  $A$  pode ser definido como uma coleção de objetos com valores de pertinência variando entre 0 (exclusão completa) e 1 (pertinência completa). Portanto, os conjuntos *fuzzy* representam uma generalização dos conjuntos clássicos. Para melhor compreensão do estudo da teoria dos conjuntos *fuzzy*, a seguir será apresentado o conceito de função de pertinência.

#### 4.1.1 Funções de Pertinência

Um conjunto *fuzzy* é definido pela função de pertinência  $\mu_A(x)$  que estabelece para cada  $x$  um grau de pertinência ao conjunto  $A$ , com  $\mu_A(x) \in [0, 1]$  (DELGADO, 2002). De maneira formal, toda função  $A : \mathbf{X} \rightarrow [0, 1]$  pode ser considerada apropriada para descrever o conjunto *fuzzy* correspondente. Na prática o formato da função de pertinência é dependente do problema que se deseja resolver e deve ser representativa do conceito a ser descrito, além do que deve ser de fácil manipulação por procedimentos computacionais (PEDRYCZ; GOMIDE, 2007).

Os conjuntos clássicos podem ser vistos como um caso particular dos conjuntos *fuzzy*, no qual apenas os limites do intervalo são utilizados na definição da função de pertinência:  $\mu_A(x) \in \{0, 1\}$ ,  $x \in \mathbf{X}$ .

Exemplo: o conceito de “números próximos a 5” pode ser expresso de forma diferente, dependendo da definição da função de pertinência associada (clássica ou *fuzzy*), considerando o universo contínuo  $\mathbf{X} \in \mathfrak{R}$ :


- Nos conjuntos clássicos “números próximos a 5”

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq 4,5 \\ 1 & \text{se } 4,5 < x \leq 5,5 \\ 0 & \text{se } x > 5,5; \end{cases}$$

- Nos conjuntos *fuzzy* “números próximos a 5”

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq 4,5 \\ \frac{x-4,5}{0,5} & \text{se } 4,5 < x \leq 5 \\ \frac{5,5-x}{0,5} & \text{se } 5 < x \leq 5,5 \\ 0 & \text{se } x > 5,5. \end{cases}$$

As diferenças entre as funções de pertinência no caso de conjuntos clássicos e *fuzzy* podem ser observadas na Figura 11.



**Figura 11: Funções de pertinência: (a) Conjuntos clássicos, (b) Conjuntos *fuzzy***

**Fonte: Delgado (2002).**

Geralmente o formato das funções de pertinência é restrito a uma certa classe de funções, representadas por alguns parâmetros específicos. Os formatos mais comuns são: triangular, trapezoidal e Gaussiano. Além dos formatos tradicionais existe uma forma bastante utilizada em aplicações práticas: o conjunto unitário (*singleton*) (PEDRYCZ; GOMIDE, 1998).

A diferença entre os formatos, especificado pelos parâmetros associados a cada caso, podem ser vistos através da Figura 12.

- Função Triangular: parâmetros  $(a, m, b)$ , com  $a \leq m \leq b$

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq a \\ \frac{x-a}{m-a} & \text{se } a < x \leq m \\ \frac{b-x}{b-m} & \text{se } m < x \leq b \\ 0 & \text{se } x > b; \end{cases}$$

- Função Trapezoidal: parâmetros  $(a, m, n, b)$ , com  $a \leq m, n \leq b$  e  $m < n$

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq a \\ \frac{x-a}{m-a} & \text{se } a < x \leq m \\ 1 & \text{se } m < x \leq n \\ \frac{b-x}{b-n} & \text{se } n < x \leq b \\ 0 & \text{se } x > b; \end{cases}$$

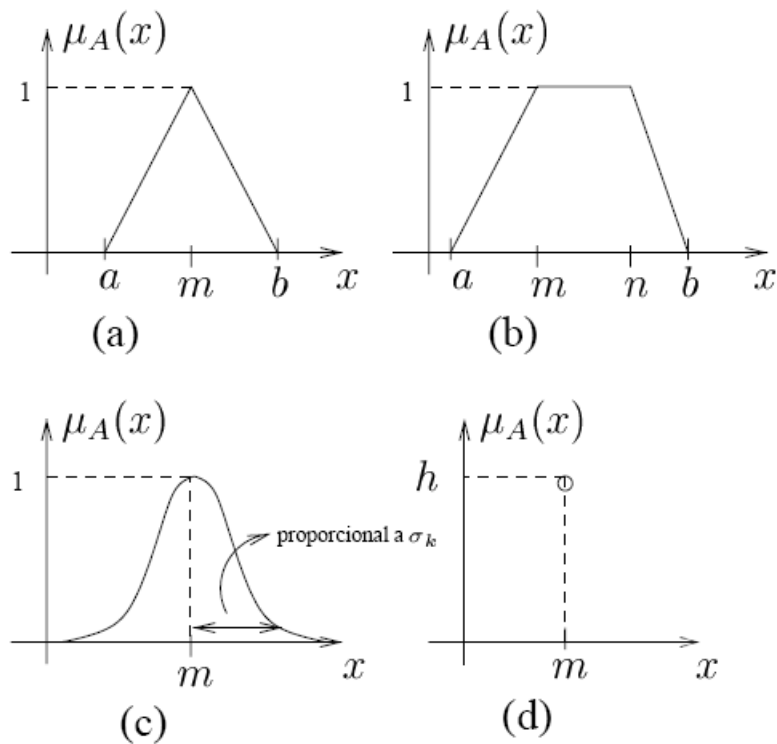
- Função Gaussiana: parâmetros  $(m, \sigma_k)$ , com  $\sigma_k > 0$

$$\mu_A(x) = \exp^{-\sigma_k(x-m)^2};$$

- Conjunto Unitário (*singleton*): parâmetros  $(m, h)$

$$\mu_A(x) = \begin{cases} h, & \text{se } x = m; \\ 0, & \text{caso contrário.} \end{cases}$$

No trabalho proposto nessa dissertação, as funções de pertinência serão definidas pelo especialista e têm formatos trapezoidais.



**Figura 12: Diferentes formatos das funções de pertinência: (a) Triangular, (b) Trapezoidal, (c) Gaussiana, (d) Singleton**

**Fonte: Almeida (2007).**

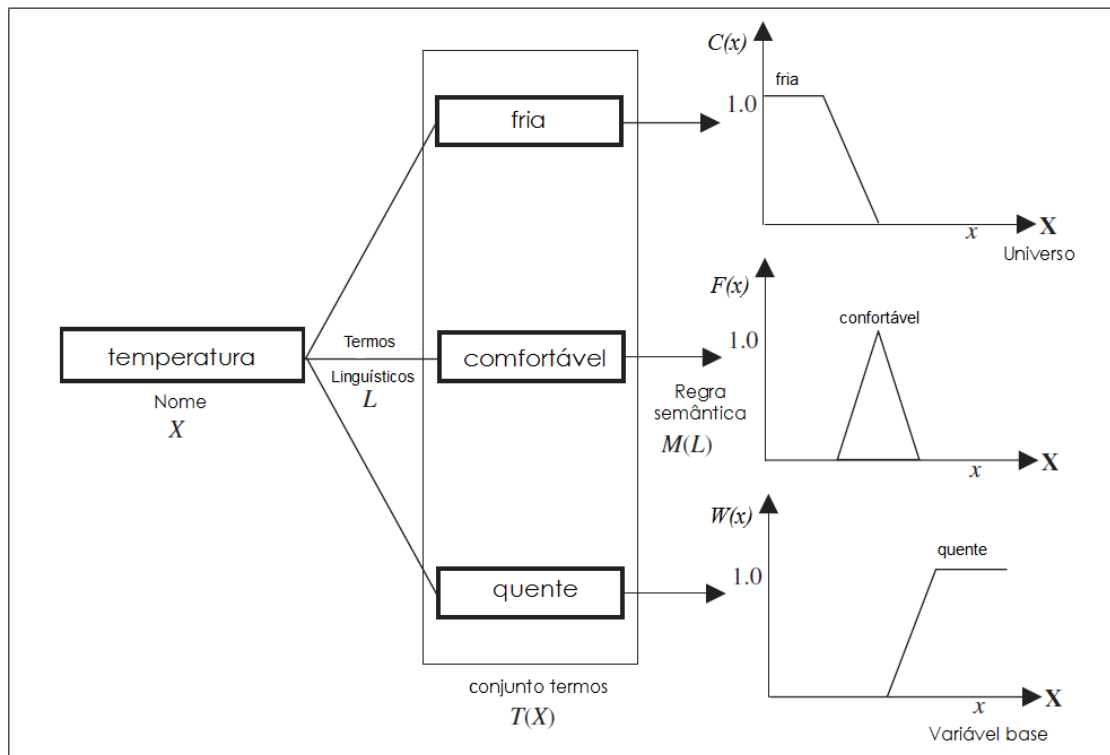
## 4.2 BASE DE DADOS

A base de dados contém informações relacionadas às variáveis linguísticas do sistema e suas partições. Uma variável linguística pode ser definida como uma variável onde os valores são palavras ou sentenças ao invés de números (ZADEH, 1965).

Um exemplo de uma variável linguística pode ser visto na Figura 13. Conforme discutido na seção 4.1, neste caso,  $X = \text{temperatura}$  e o conjunto de termos linguístico poderia ser dado por  $T(\text{temperatura}) = \{\text{fria, confortável e quente}\}$ . Os termos fria e quente são associados a funções de pertinência trapezoidais, enquanto o termo confortável é associado a uma função de pertinência triangular. O universo  $X$  da variável não está declarado, mas poderia ser definido



entre o intervalo  $[-10,40]$ .



**Figura 13: Exemplo de Variável Linguística**

Fonte: Adaptado de Pedrycz e Gomide (2007).

Na seção a seguir será explicada a Base de Regras, a qual faz uso das variáveis linguísticas.

#### 4.3 BASE DE REGRAS

Regras *fuzzy* são muito apropriadas para representar o conhecimento linguístico/empírico, associando variáveis de entrada às de saída através de conceitos vagos mas que podem ser facilmente compreendidos pelo ser humano.

As regras *fuzzy* são expressões na forma (ZADEH, 1965):

SE  $\{$ antecedente $\}$  ENTÃO  $\{$ consequente $\}$ .

Os antecedentes e consequentes são proposições do tipo  $L$  é  $l$  onde  $L$  é uma variável linguística e  $l$  um rótulo da variável linguística associado a um conjunto *fuzzy*. Como exemplo tem-se a regra, SE temperatura é quente então o resfriamento é alto, onde  $X$  = temperatura,  $T(X) = \{\text{fria, confortável, quente}\}$  e  $Y$  = resfriamento,  $T(Y) = \{\text{baixo, alto}\}$ ; e cada rótulo está associado a um conjunto *fuzzy* diferente representado por uma função de pertinência específica.

As regras podem ter múltiplas proposições como antecedente e consequente formando regras do tipo:

SE  $X_1$  é  $A_1$  E  $X_2$  é  $A_2$  E  $\dots$  E  $X_n$  é  $A_n$  ENTÃO  $Y_1$  é  $B_1$   $\dots$  E  $Y_s$  é  $B_s$ .

Um exemplo de regras com múltiplas proposições é “Se temperatura é fria E ar é seco ENTÃO aquecedor é alto e umidificador é alto”. Quando o antecedente e o consequente das regras são formados por múltiplas proposições, existe a necessidade dessas proposições serem agregadas. Para isso existem as normas-t, que são operadores de agregação válidos para regras unidas por E, cujos representantes mais conhecidos são o mínimo e o produto algébrico. Além da agregação dos antecedentes e consequentes é necessária a definição da semântica da regra. A semântica da regra é a função que define uma regra *fuzzy* como uma relação *fuzzy*  $R$  no produto cartesiano  $(\mathbf{X}_1 \times \mathbf{X}_2 \dots \mathbf{X}_n) \times (\mathbf{Y}_1 \dots \mathbf{Y}_n)$  (JANG; SUN; MIZUTANI, 1997). Neste trabalho são utilizadas conjunções *fuzzy* (semântica dada por uma norma-t=min).

Uma base de regras fuzzy é formada por um conjunto de regras onde a saída final do sistema deve considerar a influência de cada regra individual. Sendo assim, após a definição da semântica da regra que irá influenciar na derivação da saída individual da regra, é necessário definir como estas respostas individuais serão agregadas para se obter a saída *fuzzy* final. O operador mais usual para realizar esta tarefa é o *max*, mas operadores de médias também são utilizados (DELGADO, 2002).

Na literatura é possível encontrar muitos modelos de sistemas de inferência *fuzzy*, e os mesmos diferem basicamente no consequente das regras. Os principais modelos são (PEDRYCZ; GOMIDE, 1998):

- Modelo Mamdani: apresenta conjuntos *fuzzy* nos antecedentes e consequentes das regras. A saída final, representada por conjunto *fuzzy*, resulta da agregação das saídas das diversas

regras. Este modelo demanda processo de defuzzificação para obtenção de saída não *fuzzy*;

- Modelo Takagi-Sugeno: consequentes das regras são uma combinação (normalmente linear) das variáveis de entrada mais uma constante, e a saída final é a média ponderada (em função do nível de ativação) da saída de cada regra;

Neste trabalho foi utilizado o modelo Mamdani, cujo mecanismo de inferência é detalhado a seguir.

#### 4.4 MECANISMOS DE RACIOCÍNIO

Os sistemas *fuzzy* utilizam uma computação baseada na regra composicional de inferência e no raciocínio *fuzzy* (PEDRYCZ; GOMIDE, 1998). De uma forma geral, tem-se:

$$\begin{array}{ll}
 \text{(fato } P_i\text{):} & X_1 \text{ é } A_1 \text{ E } X_2 \text{ é } A_2 \text{ E } \dots \text{ E } X_n \text{ é } A_n \\
 \text{(regra } R_1\text{):} & \text{Se } X_1 \text{ é } A_1^1 \text{ E } \dots \text{ E } X_n \text{ é } A_n^1 \text{ então } Y_1 \text{ é } B_1^1 \text{ E } \dots \text{ E } Y_s \text{ é } B_s^1 \\
 & \vdots \\
 \text{(regra } R_m\text{):} & \text{Se } X_1 \text{ é } A_1^m \text{ E } \dots \text{ E } X_n \text{ é } A_n^m \text{ então } Y_1 \text{ é } B_1^m \text{ E } \dots \text{ E } Y_s \text{ é } B_s^m \\
 \hline
 \text{(conclusão } P_o\text{):} & Y_1 \text{ é } B_1 \text{ E } Y_2 \text{ é } B_2 \text{ E } \dots \text{ E } Y_s \text{ é } B_s .
 \end{array}$$

A forma como a conclusão é extraída a partir do fato  $P_i$  e das regras  $R_1$  a  $R_m$  define diferentes mecanismos de inferência utilizados por sistemas *fuzzy*. Existem dois mecanismos de inferência principais: inferência composicional e inferência escalonada (também chamada de modelo MinMax). O esquema do modelo MinMax simplifica muito a computação em SIF. Por isso, a maioria das aplicações práticas utiliza SIF baseados neste mecanismo (PEDRYCZ; GOMIDE, 2007).

O mecanismo de inferência adotado neste trabalho é o MinMax e será descrito a seguir.

#### 4.4.1 Inferência Escalonada (Modelo MinMax)

Segundo Pedrycz e Gomide (2007), o esquema geral do modelo MinMax para um sistema *fuzzy* composto por  $m$  regras *fuzzy* ( $R_j, j = 1, \dots, m$ ) envolve os seguintes passos:

**Passo 1 Matching:** para cada regra, computar o nível de similaridade (*matching*)  $\mu_{m_k}, k = 1, \dots, n$ , entre cada proposição atômica<sup>1</sup> (associada à variável  $k$ ) do antecedente da regra e a proposição atômica correspondente no fato (ou proposição de entrada  $P_i$ ). A operação de *matching* pode ser relacionada com a composição sup-**min**, o que, no caso de uma entrada crisp  $u_k$ , resulta no matching dado por  $\mu_{m_k} = \mu_{A_k}(u_k)$ .

**Passo 2 Agregação dos antecedentes:** para cada regra, computar o grau de ativação  $\mu_j$  da regra  $R_j$  da seguinte forma:

$$\mathbf{A}_a = \mu_j = \min(\mu_{m_1}, \mu_{m_2}, \dots, \mu_{m_n}).$$

**Passo 3 Derivação da conclusão individual  $P_{oj}$ :** para cada regra, computar o valor inferido, baseado no resultado da agregação dos antecedentes  $\mu_j$  e na semântica  $f$  da regra escolhida.

$$P_{oj}(y) = B^{j*}(y) = \min(\mu_j, \mu_{B^j}(y)) .$$

No trabalho desenvolvido nessa dissertação, a semântica da regra é sempre uma norma-t.

**Passo 4 Derivação do resultado final  $P_o$ :** Computar o valor inferido do conjunto completo de regras através da agregação dos valores inferidos no passo 3:

$$P_o(y) = B(y) = \max(B^{1*}, B^{2*}, \dots, B^{m*}) .$$

Como exemplo, suponha o seguinte esquema de raciocínio *fuzzy* envolvendo regras *fuzzy* com duas variáveis lingüísticas  $X_1$  e  $X_2$  no antecedente e uma variável lingüística  $Y$  no con-

---

<sup>1</sup>proposições atômicas representam unidades de informação básicas das regras e são dadas por  $X \text{ é } A$  ou ainda  $Y \text{ é } B$

seqüente,

$$\begin{array}{ll}
(\text{fato } P_i): & X_1 \text{ é } A_1 \text{ E } X_2 \text{ é } A_2 \\
(\text{regra } R_1): & \text{Se } X_1 \text{ é } A_1^1 \text{ E } X_2 \text{ é } A_2^1 \text{ então } Y \text{ é } B^1 \\
& \vdots \\
(\text{regras } R_m): & \text{Se } X_1 \text{ é } A_1^m \text{ E } X_2 \text{ é } A_2^m \text{ então } Y \text{ é } B^m \\
\hline
(\text{conclusão } P_o): & Y \text{ é } B .
\end{array}$$

A utilização deste tipo de inferência na implementação modelo MinMax depende da fixação dos seguintes parâmetros:

- agregação de antecedentes  $\mathbf{A}_a = \min$ ;
- semântica das regras  $f: f = \min$
- a agregação das regras  $\mathbf{A}_R$ : max.

Então:

**Passo 1** *Matching* na regra  $R_j$ :

$$\begin{aligned}
\mu_{m_1^j} &= \sup_{x_1} [\mu_{A_1}(x_1) \wedge \mu_{A_1^j}(x_1)] ; \\
\mu_{m_2^j} &= \sup_{x_2} [\mu_{A_2}(x_2) \wedge \mu_{A_2^j}(x_2)] .
\end{aligned}$$

**Passo 2** Agregação dos Antecedentes:

$$\mu_j = \mu_{m_1^j} \wedge \mu_{m_2^j}$$

**Passo 3** Derivação individual  $P_{oj}(y)$ :

$$P_{oj}(y) = B^{j*}(y) = f_p(\mu_j, \mu_{B^j}(y)) = \min(\mu_j, \mu_{B^j}(y))$$

**Passo 4** Conclusão final

$$P_o(y) = B(y) = \mathbf{A}_R(B^{j*}) = \max_{j=1}^m [B^{j1*}, \dots, B^{m1*}] .$$

#### 4.4.2 Inferência MinMax no Modelo Mamdani

A característica básica do modelo de Mamdani é o fato de utilizar conjuntos *fuzzy* nos consequentes das regras *fuzzy*. As etapas de cálculo de *matching* e agregação dos antecedentes seguem os passos normais do modelo MinMax. A obtenção da conclusão de cada regra depende da semântica escolhida e dos resultados do *matching* e agregação dos antecedentes (DELGADO, 2002). Da agregação das conclusões inferidas de cada regra, resulta um conjunto *fuzzy*. Nos casos em que uma saída não-*fuzzy* é necessária, utiliza-se um dos métodos de defuzzificação (ALMEIDA, 2007). O método utilizado neste trabalho foi o centro de gravidade que é dado por:

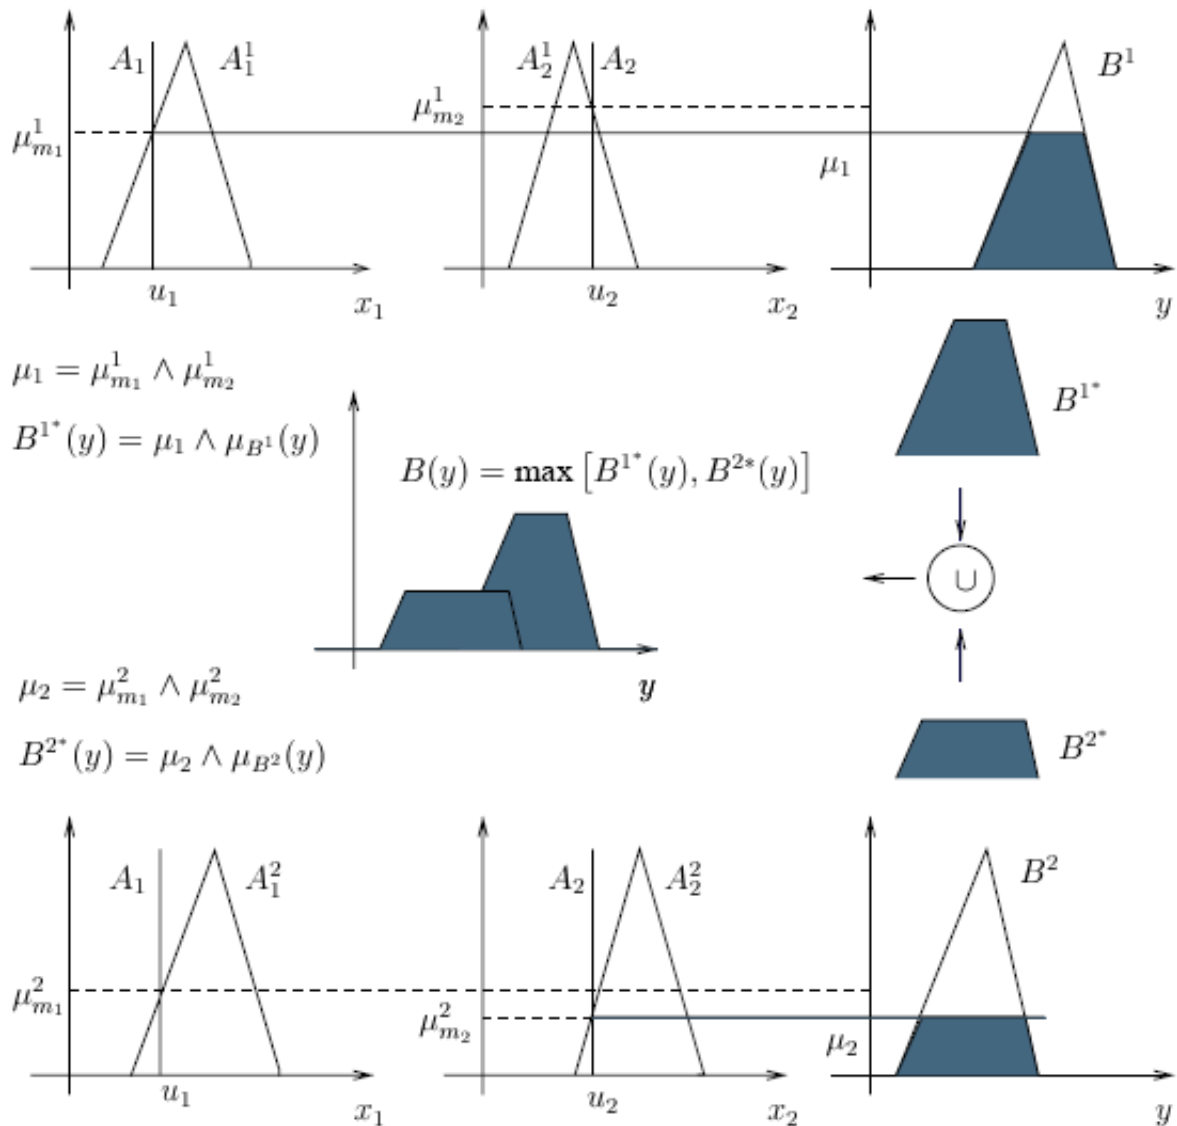
$$\text{Saída} = \frac{\int_y \mu_B(y)y \, dy}{\int_y \mu_B(y) \, dy}$$

onde  $B$  é um conjunto *fuzzy* definido no universo  $\mathbf{Y}$ .

Suponha um sistema *fuzzy* do tipo Mamdani, composto por duas regras nebulosas na forma

$$R_j : \text{Se } X_1 \text{ é } A_1^j \text{ E } X_2 \text{ é } A_2^j \text{ então } Y \text{ é } B^j, \quad j = 1, 2 \quad ,$$

onde  $X_1$  e  $X_2$  são variáveis lingüísticas e  $A_1^j$  e  $A_2^j$  são conjuntos *fuzzy* nos universos  $\mathbf{X}_1$  e  $\mathbf{X}_2$ , respectivamente. A Figura 14 ilustra o processo de inferência do Modelo MinMax para duas entradas não-*fuzzy* (representadas por valores em posições arbitrárias  $u_1$  e  $u_2$ ). Neste exemplo, a agregação dos antecedentes é dada pelo *min*, a semântica das regras é fixada como  $f = f_m = \min$  e a união das saídas de cada regra é computada pelo operador *max*.



**Figura 14: Inferência no modelo Mamdani**

Fonte: Delgado (2002).





## 5 DESPACHO ECONÔMICO DE ENERGIA ELÉTRICA

O Despacho Econômico é o estudo da alocação ótima de uma demanda entre os geradores de um sistema de geração termoelétrica. É importante garantir que as condições de operação sejam satisfeitas, sendo assim, obtêm-se as potências ótimas de saída para cada gerador de energia. Este problema busca minimizar o custo de produção de energia elétrica por meio da otimização da distribuição da produção entre as unidades geradoras e da utilização eficiente dos recursos energéticos. Esta minimização do custo de produção passa pela utilização racional do combustível utilizado nos geradores de energia (RODRIGUES, 2007; SINHA; CHAKRABARTI; CHATTOPADHYAY, 2004).

Existem outras abordagens relacionadas ao problema de Despacho Econômico de energia elétrica: Despacho Ambiental e Despacho Econômico/Ambiental (problema multiobjetivo). Esses dois novos modelos serão brevemente descritos a seguir, visto que não serão tratados nesse trabalho.

O objetivo do problema do Despacho Ambiental é minimizar a emissão de poluentes no meio ambiente, atendendo a demanda necessária de energia. Ou seja, o objetivo é encontrar os níveis mínimos de concentração que resultam da relação entre a quantidade de cada poluente e a saída de potência dos geradores para satisfazer uma determinada demanda (RODRIGUES, 2007).

O problema de Despacho Econômico/Ambiental combina o custo de combustível e emissão de poluentes em uma função com ajuste de diferentes pesos. Como nem sempre minimizar a emissão significa minimizar o custo, pode existir um conflito entre os objetivos. Sendo assim são utilizadas técnicas de otimização multiobjetivo para solucionar o problema considerando

que determinadas exigências sejam satisfeitas para casos distintos.

## 5.1 MODELO MATEMÁTICO

A Equação 5 apresenta u modelo matemático para o problema do Despacho Econômico.

$$\begin{aligned}
 &\text{Minimizar } F = \sum_{j=1}^n F_j(P_j) \\
 &\text{sujeito a :} \\
 &\sum_{j=1}^n P_j = PD \\
 &P_j^{\min} \leq P_j \leq P_j^{\max}
 \end{aligned} \tag{5}$$

A função  $F$  representa o custo total de geração da energia elétrica,  $F_j(P_j)$  identifica o custo de cada gerador  $j$ ,  $P_j$  é a potência de saída do  $j$ -ésimo gerador,  $P_j^{\min}$  e  $P_j^{\max}$  representam, respectivamente, as potências mínima e máxima de geração de energia de cada gerador e  $PD$  é a demanda de energia elétrica a ser atendida. É importante salientar que neste modelo as perdas de transmissão são desconsideradas.

Na função custo de cada gerador, é utilizada a função quadrática apresentada na Equação 6:

$$F_j(P_j) = a_j P_j^2 + b_j P_j + c_j, \tag{6}$$

onde  $P_j$  é a potência da  $j$ -ésima unidade geradora e  $a_j$ ,  $b_j$  e  $c_j$  são os coeficientes característicos da função.

Um modelo mais rigoroso para o problema de Despacho Econômico é dado pela Equação 7, conhecido como Despacho Econômico com efeito de ponto de válvula, tal que

$$F_j(P_j) = a_j * P_j^2 + b_j * P_j + c_j + |e_j * \text{seno}(f_j * (P_j^{\min} - P_j))|, \tag{7}$$

onde  $P_j$  é a saída da  $j$ -ésima unidade geradora,  $a_j$ ,  $b_j$ ,  $c_j$ ,  $e_j$  e  $f_j$  são coeficientes da função de custo da  $j$ -ésima unidade com efeito de ponto de válvula.

Este modelo que considera o efeito de ponto de válvula será o modelo utilizado nesse trabalho, no entanto, três instâncias diferentes serão testadas, cada uma considerando quantidades de geradores ou PD diferentes, conforme detalhado no capítulo 7.

## 5.2 TRABALHOS CORRELATOS

Nessa seção serão descritos alguns trabalhos relacionados ao problema do despacho econômico que utilizam metodologias semelhantes para a obtenção da solução do problema.

### 5.2.1 Um Algoritmo Cultural para Problemas do Despacho Econômico e Ambiental de Energia Elétrica

No trabalho de Rodrigues (2007) é apresentado um Algoritmo Cultural com Espaço Populacional representado por um Algoritmo Genético para solucionar problemas de Despacho Econômico, Despacho Ambiental e Despacho Econômico/Ambiental.

O Algoritmo Genético possui uma população de cromossomos (indivíduos), operadores genéticos específicos (variações do cruzamento aritmético e da mutação gaussiana), um método de seleção dos pais e um método de seleção de indivíduos da próxima geração.

O Espaço de Crença é responsável por armazenar os conhecimentos e utilizá-los através das funções de influência, como guia para a nova geração de indivíduos. A Função de Aceitação implementada atua dinamicamente, variando de geração para geração. A Função de Influência Principal determina qual a probabilidade de cada conhecimento ser utilizado de acordo com o sucesso que eles tiveram na última geração.

Neste trabalho foram utilizados três tipos de conhecimentos: Conhecimento Situacional, Conhecimento Normativo e Conhecimento Situacional/Normativo.

O Conhecimento Situacional armazena, em uma árvore vermelha e preta, os melhores indivíduos encontrados até o momento e os utiliza como modelos ou guias na evolução dos demais

indivíduos. No Conhecimento Normativo são armazenados os intervalos de valores de cada gene onde bons indivíduos se concentram e o objetivo desse conhecimento é manter os valores dos genes dos indivíduos da população dentro ou o mais próximo desses intervalos. O Conhecimento Situacional/Normativo une conceitos de dois conhecimentos, Situacional e Normativo. A escolha dos indivíduos que participarão dos operadores são baseados nas características de escolha do Conhecimento Situacional. A forma como os indivíduos serão influenciados pela mutação e cruzamento é regida pelas regras aplicadas no Conhecimento Normativo.

Os resultados obtidos pela abordagem proposta são comparáveis e em alguns casos superiores àqueles publicados na literatura, demonstrando o bom comportamento do algoritmo.

Como discutido no trabalho, *“infelizmente, a maioria dos trabalhos da área apresentam apenas os melhores valores obtidos pelas técnicas propostas, dificultando as comparações entre as técnicas. No único caso onde esse tipo de comparação foi possível o comportamento do algoritmo proposto foi superior ao do algoritmo reportado na literatura (tanto no melhor caso, quanto no caso médio e no pior caso), mais uma vez atestando a eficiência do método proposto”* (RODRIGUES, 2007).

### 5.2.2 Um Sistema Imune Cultural para o Problema do Despacho Econômico

No trabalho de Gonçalves et al. (2007) é proposto um Algoritmo Cultural onde o Espaço Populacional é representado por um Sistema Imunológico Artificial, baseado na teoria da Seleção Clonal, para solucionar o Problema do Despacho Econômico.

O Espaço de Crenças foi utilizado para extrair informações da população de anticorpos, usando essas informações como guia para gerar novos indivíduos por meio das funções de influências. Os protocolos de comunicações determinam quais anticorpos serão escolhidos durante o processo de atualização do espaço de crenças (por meio da função de aceitação) e a probabilidade de um conhecimento armazenado no espaço de crenças influenciar o operador de hipermutação (através da função de influência principal).

Foi utilizada uma função de aceitação dinâmica, para que no início da evolução muitos anticorpos contribuam com os conhecimentos (pois existe pouco conhecimento, inicialmente) e

no final da evolução poucos anticorpos contribuam (onde muito conhecimento já foi adquirido). A função de influência principal é responsável pela escolha de qual conhecimento aplicar nos operadores de hipermutação; inicialmente, todos os conhecimentos possuem a mesma probabilidade de serem aplicados (0.25) e no decorrer da evolução esta probabilidade vai sendo alterada (mas é garantido que durante o processo de evolução pelo menos 10% de cada conhecimento seja aplicado na população).

Foram utilizados quatro fontes de conhecimento: Conhecimento Situacional, Normativo, Histórico e Topográfico. O conhecimento situacional armazena os melhores anticorpos encontrados na população e faz com que esses anticorpos sirvam como guias para influenciar os demais anticorpos. No conhecimento normativo são armazenados intervalos onde são encontradas boas soluções para o problema e são utilizadas para mover novas soluções para dentro desses intervalos. O conhecimento histórico guarda eventos importantes ocorridos durante o processo de evolução. Um exemplo disso é quando o algoritmo encontra um mínimo local, então esse evento é armazenado para que num próximo evento semelhante, o algoritmo saiba qual decisão tomar. No conhecimento topográfico é gerado um mapa, que consiste num conjunto de regiões e o melhor indivíduo de cada região. Também é armazenada uma lista ordenada com as melhores regiões, ordenada pelos melhores indivíduos.

Os resultados mostraram que o algoritmo proposto em Gonçalves et al. (2007) foi melhor em dois de três *benchmarks* utilizados no problema. Isso comprova a eficiência de se utilizar Algoritmos Culturais.

Este trabalho de dissertação está fortemente baseado em Gonçalves et al. (2007), no entanto aqui uma função de influência baseada em Sistemas de Inferência *Fuzzy* é utilizada em substituição à função de influência principal dinâmica. Detalhes serão fornecidos no Capítulo 6.

### 5.2.3 Um Algoritmo Cultural com Evolução Diferencial aplicado ao Problema de Despacho Econômico de Energia Elétrica

O trabalho desenvolvido em Coelho, Almeida e Mariani (2008) propõe um algoritmo baseado em um Algoritmo Cultural (AC) e com Evolução Diferencial (ED). Este algoritmo é aplicado ao

Problema de Despacho Econômico de 13 geradores considerando o efeito de ponto de válvula.

Neste trabalho novos conceitos de otimização são apresentados tendo como base os conhecimentos normativo e situacional dos algoritmos culturais, e estes novos conceitos são aplicados ao espaço populacional proposto o qual é baseado em evolução diferencial.

O conhecimento situacional consiste no melhor exemplar encontrado ao longo da evolução no espaço populacional (evolução diferencial). Esse exemplar representa um líder para os outros indivíduos da população. Já o conhecimento normativo contém os intervalos onde boas soluções têm sido encontradas, buscando mover novas soluções para dentro desses intervalos. Assim, a equação básica que rege a operação de perturbação (mutação) na ED é modificada pela influência do conhecimento normativo e situacional. Assim, se o novo indivíduo gerado após a mutação está fora dos limites de factibilidade o conhecimento normativo atua na tentativa de corrigí-lo; senão, o conhecimento situacional atua influenciando o novo indivíduo na tentativa de aproximá-lo do melhor indivíduo. No caso onde soluções infactíveis são produzidas, utiliza-se um método de penalidade proposto pelo próprio autor em outro trabalho (COELHO; MARIANI, 2006).

A metodologia proposta nesse trabalho de Coelho, Almeida e Mariani (2008), foi comparada à versão de Evolução Diferencial pura (sem o algoritmo cultural) e ainda com alguns dos melhores métodos da literatura (para o caso de 13 geradores com demanda de 1800 MW). Os resultados mostraram que o uso dos conhecimentos traz ganho de desempenho tanto em termos de média quando do melhor resultado encontrado. Na comparação com as outras abordagens o melhor resultado encontrado pelo algoritmo híbrido foi superior a todos os outros.

#### 5.2.4 Evolução Diferencial com Algoritmos Culturais aplicados na solução de Problemas de Despacho Econômico

O trabalho proposto por Coelho, Souza e Mariani (2009) apresenta uma metodologia de Algoritmos Culturais com espaço populacional baseado em Evolução Diferencial aplicada em problemas de despacho econômico de energia elétrica, de 13 e 40 geradores.

Foram desenvolvidas três abordagens: um algoritmo evolutivo de Evolução Diferencial

clássico, um algoritmo de Evolução Diferencial (adaptado ao contexto Cultural) com Algoritmo Cultural e algoritmo evolutivo de Evolução Diferencial com Algoritmo Cultural utilizando uma medida de diversidade da população.

O algoritmo clássico de Evolução Diferencial utilizado aqui faz uso de suas características padrões (mutação, *crossover*) e o Algoritmo Cultural implementado utiliza dois conhecimentos: conhecimento Normativo e Situacional. O conhecimento Situacional consiste no melhor exemplar encontrado durante o processo evolucionário e o mesmo é utilizado como um líder para os outros indivíduos. Já o conhecimento Normativo contém intervalos onde boas soluções têm sido encontradas e tenta mover novas soluções para dentro desses intervalos. O número de indivíduos aceitos para atualizar o espaço de crenças é selecionado aleatoriamente de uma parte da população utilizando a fórmula  $n_{accepted} = pN$ , onde  $n_{accepted}$  é o número de indivíduos aceitos,  $p$  é um parâmetro dado pelo usuário (nesse trabalho foi adotado  $p = 0.3$ ) e  $N$  é o tamanho da população.

A diferença entre o modelo Cultural e o Cultural baseado na proporção da diversidade da população é que, utilizando-se de uma medida da diversidade da população (calculada por meio de uma fórmula), é possível escapar mais facilmente de um mínimo local do que em um método tradicional de Evolução Diferencial. Uma das vantagens em se utilizar uma medida da diversidade da população é que regiões promissoras são encontradas rapidamente durante a fase inicial do processo evolutivo.

Os resultados obtidos provam que o método proposto é eficiente e os resultados do método Cultural baseado na medida da diversidade da população foram melhores entre os métodos comparados no trabalho.

### 5.2.5 Um Sistema Imune aplicado a Problemas de Despacho Econômico

No trabalho desenvolvido por Vanaja, Hemamalini e Simon (2008) é apresentado um algoritmo de SIA aplicado a Problemas de Despacho Econômico com diferente número de geradores.

O algoritmo de SIA utilizado é o clássico baseado em seleção clonal, onde uma população

de anticorpos aleatoriamente inicializada, dá origem aos clones, os quais sofrem um processo de hipermutação e passam por um processo de seleção baseada na afinidade (qualidade da solução na resolução do problema).

A afinidade (*fitness*) é dada pela seguinte equação:  $Fitness = A[1 - \%Cost] + B[1 - \%Error]$ ; onde A e B são coeficientes de ponderação (assumindo valores maiores do que zero), e *Cost* e *Error* são dados por fórmulas que verificam o que tem sido produzido e as perdas dentro da população.

Na geração da população inicial, *N* anticorpos são gerados de forma aleatória. Um processo de codificação binária em uma string de *l* bits é utilizado e a ele é associado um processo de normalização que garante a factibilidade dos indivíduos gerados. A taxa de mutação é inversamente proporcional ao fitness (indivíduos bons tendem a sofrer pouca mutação enquanto que indivíduos ruins tendem a ser mais modificados) e varia no intervalo de 0,1 a 0,5. Após a mutação a codificação binária é convertida em real e os indivíduos são avaliados e, em caso de violação de alguma restrição, o indivíduo é penalizado. Uma vez mutados os clones passam por um processo de seleção por torneio onde um total de *N* indivíduos são selecionados para compor a próxima geração da população.

Como citado no trabalho, o algoritmo foi exaustivamente testado variando o tamanho da população e o número de clones. Os resultados das simulações mostram que a técnica desenvolvida é de fácil implementação e capaz de encontrar valores próximos ao ótimo global.

Para validar a proposta do algoritmo, o mesmo foi aplicado em várias instâncias do problema, incluindo os casos de 3, 13 e 40 geradores, com a presença de efeito de ponto de válvula. Os resultados obtidos comprovam a robustez, rápida convergência e eficiência da metodologia proposta.

Vale salientar aqui que os valores utilizados nos parâmetros foram relativamente altos, em relação a outras propostas. Por exemplo, no caso de 40 geradores é utilizada uma população com 320 indivíduos e o número de clones produzido por cada anticorpo foi definido como 20.



### 5.2.6 Evolução Diferencial aplicado a Problemas de Despacho Econômico

Noman e Iba (2008) apresentam um modelo de Evolução Diferencial para problemas de despacho econômico de energia elétrica. Foram aplicados cinco casos distintos do problema para comprovar a eficácia do método proposto.

A população inicial é gerada aleatoriamente respeitando as restrições do problema. Em seguida o método tenta localizar a solução ótima global através de um refinamento utilizando reprodução e seleção. Diferentemente de outros métodos evolutivos, cada indivíduo da geração atual gera sua prole por meio de cruzamentos com outros indivíduos aleatoriamente selecionados. São selecionados três indivíduos aleatoriamente (todos distintos) e os mesmos são utilizados para gerar um indivíduo mutante, por meio de um operador denominado mutação diferencial. Após a fase de mutação, o método utiliza um operador chamado *crossover* binomial, em qual o indivíduo mutado é acoplado a um indivíduo original da população e o filho (ou indivíduo tentativa) é gerado. Os genes do indivíduo filho são herdados do indivíduo mutado e do indivíduo original, determinados por um parâmetro chamado probabilidade de *crossover*. Após esses processos, é realizada uma competição entre o indivíduo original e o filho gerado, e o vencedor, que é selecionado deterministicamente baseado no valor de *fitness*, é promovido para próxima geração. Esses passos de reprodução e seleção são repetidos geração após geração até que o critério de parada seja satisfeito.

Nesse trabalho de Noman e Iba foi utilizado um método especializado para manipular as restrições do problema de despacho, com o objetivo de satisfazer as restrições de igualdade e desigualdade. Na geração inicial, as restrições do problema são satisfeitas, visto que os indivíduos são gerados dentro de um intervalo factível. Mas com o decorrer do processo e aplicação dos operadores, indivíduos infactíveis podem surgir na população. Para tratar disso, caso o indivíduo exceda o limite, uma certa quantia é retirada dele e caso ele não tenha produzido o limite mínimo, é acrescentada uma certa quantia.

O paradigma desenvolvido foi aplicado em alguns casos do problema de despacho econômico de energia elétrica. Em dois casos do problema com efeito de ponto de válvula o método proposto encontrou as melhores soluções comparados aos melhores resultados encontrados até o

momento. Considerando os resultados da aplicação em problemas de despacho com diferentes características, dimensões, exigências e restrições, pode-se concluir que o método tem um desempenho melhor comparado a outros métodos com bons resultados.

## 6 UM SISTEMA IMUNE FUZZY CULTURAL PARA PROBLEMAS DO DESPACHO ECONÔMICO

Neste capítulo será detalhado o Algoritmo Cultural com espaço populacional baseado em Sistema Imunológico Artificial proposto para resolver diferentes instâncias do problema de despacho econômico de energia elétrica.

O capítulo 3 apresentou alguns conceitos básicos dos Algoritmos Culturais (AC), salientando a característica híbrida desses algoritmos. Deste modo os AC podem ser desenvolvidos juntamente com outros algoritmos (a restrição é que sejam algoritmos evolutivos). O trabalho desenvolvido nesta dissertação utiliza um Sistema Imune Artificial inspirado na Teoria da Seleção Clonal (Clonalg) no espaço populacional do Algoritmo Cultural e inclui ainda um mecanismo de ajuste baseado em um sistema *fuzzy* para a função de influência. Este sistema será denominado Sistema Imune *Fuzzy* Cultural.

### 6.1 ESPAÇO POPULACIONAL

Conforme já mencionado, o Espaço Populacional é o componente dos Algoritmos Culturais responsável pela evolução genética dos indivíduos de uma população. O interesse em utilizar um Sistema Imune Artificial é justificado por provas recentes que essa classe de algoritmos é capaz de encontrar o ótimo global de um problema de otimização (CUTELLO et al., 2007).

A Tabela 1 apresenta um paralelo entre os elementos da biologia e os componentes do algoritmo proposto.

O Clonalg originalmente desenvolvido por Gonçalves et al. (2007) pode ser visto no pseudocódigo do Algoritmo 3.

**Tabela 1: Comparação entre os elementos biológicos e os elementos do algoritmo.**

<b>Biologia</b>	<b>Algoritmo</b>
Anticorpo	Uma solução válida (demanda suprida)
Antígeno	Demanda a ser atendida (problema a ser solucionado)
Interação Anticorpo x Antígeno	O custo total dos geradores (aptidão de um anticorpo)
Clonagem	Replicação dos bons indivíduos (bons geradores, bons resultados)
Hipermutação	Tentativa de melhorar as saídas dos geradores

**Fonte: Autoria própria.**

---

### **Algoritmo 3** Algoritmo do SIA Desenvolvido Originalmente

---

#### **Clonalg original**

Inicie a População;

Avalie a População;

#### **Enquanto o critério de término não for satisfeito**

Clone a população;

Aplique a hipermutação

Aplique a busca local (*Quasi-Simplex*);

Repare os indivíduos ineficazes;

Avalie os clones;

Aplique o operador de *Aging* na População e nos Clones;

Aplique o operador de Seleção;

#### **Fim Enquanto**

---

Neste algoritmo, cada anticorpo é uma combinação válida de saída de energia (codificada como números reais) para as unidades geradoras. Assim um anticorpo é composto por  $n$  componentes (geradores de energia - para um problema de 13 geradores, 13 componentes, e para um problema com 40 geradores, 40 componentes) que são iniciados na primeira geração, como apresentado na Equação 8.

$$ant_{i,j} = P_i^{min} + U(0,1) * (P_i^{max} - P_i^{min}), \quad (8)$$

onde  $ant_{i,j}$  é o  $j$ -ésimo componente do  $i$ -ésimo anticorpo (isto é, a saída de energia da  $j$ -ésima unidade geradora - codificada na  $i$ -ésima combinação de unidades geradoras),  $U(0,1)$  é uma variável aleatória obtida a partir de uma distribuição uniforme no intervalo  $[0,1]$ ,  $P_i^{max}$  e  $P_i^{min}$  são, respectivamente, as saídas máxima e mínima permitidas para a  $j$ -ésima unidade. Esse processo de inicialização garante que nenhum anticorpo viola as restrições operacionais das unidades geradoras.

A afinidade de um anticorpo com o antígeno, a qual mede a qualidade da solução representada, é dada pela Equação 9, tal que

$$aff_i = (MaxCost_{gen} - Cost_i) / (MaxCost_{gen} - MinCost_{gen}), \quad (9)$$

onde  $Cost_i$  é o custo total de combustível da  $i$ -ésima configuração (custo este representado por  $F$  na Equação 6),  $MinCost_{gen}$  e  $MaxCost_{gen}$  são os custos de combustível mínimo e máximo, respectivamente, entre todos os anticorpos presentes na geração  $gen$ .

Após a avaliação da geração inicial, o Sistema Imune entra no laço principal (que representa o estágio de maturação de afinidade do algoritmo). O laço é repetido até que o critério de término seja satisfeito. O critério de parada adotado nesse trabalho é o número máximo de gerações.

O processo de maturidade da afinidade inicia pela clonagem dos anticorpos, onde o número de clones de cada anticorpo é estático ( $dup$ ), isto é, independente da afinidade do anticorpo.

Na sequência são aplicados os operadores de hipermutação. O algoritmo implementado utiliza dois operadores de hipermutação: uma Hipermutação Gaussiana Adaptativa (*Adaptive Gaussian Hypermutation - AGH*) e uma Hipermutação Cauchy Adaptativa (*Adaptive Cauchy Hypermutation - ACH*) e a diferenciação entre os dois se dá apenas na distribuição de probabilidade utilizada. Os operadores de hipermutação são dados na Equação 10.

$$ant_{i,j}^h = ant_{i,j} + mult * (Cost_i / MinCost_{gen}) * R(0,1) * (P_j^{max} - P_j^{min}) \quad (10)$$

Onde  $ant_{i,j}^h$  é o  $j$ -ésimo componente (após a hipermutação) do  $i$ -ésimo anticorpo,  $ant_{i,j}$  é o valor atual da  $j$ -ésima unidade geradora do  $i$ -ésimo indivíduo,  $mult$  é um multiplicador adaptativo (ele tenta fazer a busca mais intensamente no início da evolução e mais suave no final da mesma) dado por  $mult = e^{-gen/\varphi}$  ( $\varphi$  é um parâmetro que dita a diminuição da velocidade do multiplicador),  $P_j^{max}$  e  $P_j^{min}$  são os limites máximo e mínimo da  $j$ -ésima unidade geradora, respectivamente,  $R(0,1)$  é um número aleatório obtido de acordo com a distribuição (Gaussiana ou Cauchy) dependendo do tipo da hipermutação. A escolha da hipermutação é feita com base na qualidade do indivíduo gerado (escolhe-se aquela que produziu o melhor indivíduo). Em ambos os casos as distribuições possuem média igual a zero e variância igual a um. De acordo com Cortés, Trejo-Pérez e Coello (2005) valores gerados pela distribuição de *Cauchy* permitem passos (relativamente) largos (*coarse-grained*), enquanto valores *Gaussian* produzem passos estreitos (*fine-grained*), o que teoricamente fornece mais flexibilidade na busca.

O termo  $Cost_i / MinCost_{gen}$  executa a mutação mais intensiva em anticorpos com um alto custo de combustível (baixa afinidade) e é mais suave em anticorpos com baixo custo de combustível (alta afinidade).

O número de mutações aplicadas em cada anticorpo é dado por:

$$M(i) = \frac{e^{-aff_i}}{\rho} * n \quad (11)$$

onde  $M(i)$  é o número de mutações aplicadas no  $i$ -ésimo anticorpo,  $aff_i$  é a afinidade do  $i$ -ésimo

anticorpo,  $\rho$  é um parâmetro que regula o número de mutações e  $n$  é o número de unidades geradoras. Assim quanto maior a afinidade (maior qualidade da solução) menor o número de mutações realizadas (menor perturbação na solução obtida).

Após a aplicação da hipermutação, um método *quasi-Simplex* (descrito no Anexo A) é aplicado como um procedimento de busca local nos melhores anticorpos entre os clones da hipermutação. Neste momento as restrições podem ser violadas, o que poderia causar anticorpos inactíveis. Para evitar tal violação, um processo de reparação é aplicado em cada clone para garantir que os anticorpos gerados são viáveis (soluções factíveis). Assim, ao invés dos anticorpos inviáveis serem penalizados, eles são reparados. O procedimento implementado é apresentado no algoritmo 4.

No trabalho de Michalewicz e Schoenauer (1996) são apresentadas técnicas de manipulação de restrições que surgiram nos últimos anos, e foram separadas em quatro categorias, como podem ser observadas nos itens abaixo:

1. Métodos baseados na preservação da viabilidade da solução, muitas vezes utilizando operadores especializados para transformar o inactível em factível;
2. Métodos baseados em funções de penalização onde o *fitness* de indivíduos inactíveis são penalizados de diferentes formas;
3. Métodos que fazem uma separação entre soluções factíveis e inactíveis, e prefere uma solução factível com baixo valor objetivo a uma solução inactível com alto valor objetivo;
4. Métodos híbridos que combinam técnicas evolucionárias com procedimentos determinísticos.

Nesse trabalho de dissertação foram utilizados os itens 1 e 2 descritos acima: um método que visa preservar a viabilidade da solução (método de reparação) e um método onde os indivíduos inactíveis são penalizados (método de penalização).

Após a aplicação do procedimento de reparação, a afinidade dada na Equação 9 pode ser utilizada para avaliar a qualidade dos indivíduos.

---

**Algoritmo 4** Procedimento de Reparação
 

---

```

  Repita para cada componente  $j$  de um anticorpo  $i$ 
    Se  $ant_{i,j} \notin P_j^{min}$ 
       $ant_{i,j} = P_j^{min}$ 
    Senão
      Se  $ant_{i,j} \notin P_j^{max}$ 
         $ant_{i,j} = P_j^{max}$ 
      Fim Se
    Fim Repetição
  Enquanto  $\sum_{i=1}^n P_i \neq PD$ 
    Selecione um componente  $j$  aleatoriamente
    Se  $\sum_{i=1}^n P_i \notin PD$ 
      Adicione uma quantidade em  $ant_{i,j}$  que não viole as restrições operacionais
      e minimize a violação de demanda de energia
    Senão
      Subtraia uma quantidade em  $ant_{i,j}$  que não viole as restrições operacionais
      e minimize a violação de demanda de energia
    Fim Enquanto
  
```

---

Em seguida é feita a aplicação de um operador de *aging*. Neste trabalho é utilizado um operador de *aging* estático puro (CUTELLO et al., 2005) (CUTELLO et al., 2006). Esse operador de *aging* elimina anticorpos antigos com o objetivo de manter a diversidade da população e evitar uma convergência prematura. Esse operador permite que um anticorpo sobreviva por até  $\tau_B$  gerações (sem melhorias), após este período é assumido que este anticorpo corresponde a um mínimo local e este deve ser eliminado da população. Um clone normalmente herda a idade do pai, mas quando o mesmo é hipermutado com sucesso (isto é, quando a hipermutação melhora a afinidade do anticorpo) sua idade é inicializada em zero.

Finalmente o último passo no processo de maturação da afinidade é a seleção dos anticorpos que irão compor a próxima população. O esquema utilizado é um operador  $(\mu + \lambda)$ -*Selection* (CUTELLO et al., 2006) o qual é aplicado nos pais e nos clones hipermutados que sobreviveram após o operador de *aging*. Ou seja, pais e filhos são avaliados juntos e são selecionados os melhores indivíduos.



## 6.2 ESPAÇO DE CRENÇA

Nesta seção serão apresentadas as alterações no Algoritmo 3 e os métodos utilizados pelas duas abordagens baseadas em Algoritmos Culturais: Imune Cultural e Imune *Fuzzy* Cultural. A abordagem Imune Cultural pode ser considerada como uma extensão do algoritmo 3, onde o Espaço de Crença e os protocolos de comunicação são adicionados para melhorar o desempenho do Sistema Imunológico original. O Sistema Imune *Fuzzy* Cultural pode ser considerado como uma extensão da versão Imune Cultural onde a função de influência é modificada para incorporar um sistema de inferência *fuzzy* (detalhado na Seção 6.2.1).

O Algoritmo Cultural desenvolvido nesse trabalho é apresentado no pseudocódigo do Algoritmo 5.

---

### **Algoritmo 5** Algoritmo Cultural Implementado

---

#### **Algoritmo Cultural**

Inicie a População;

Avalie a População;

Inicie o Espaço de Crenças;

#### **Enquanto o critério de término não for satisfeito**

    Clone a população;

    Aplique a hipermutação considerando a Função de Influência *Fuzzy* nos Clones selecionados de acordo com a probabilidade de cada fonte de conhecimento;

    Aplique a busca local (*Quasi-Simplex*);

    Aplique reparação para ambas as abordagens, penalidade (para a versão *fuzzy*);

    Avalie os Clones;

    Aplique o operador de *Aging* na População e nos Clones;

    Aplique o operador de Seleção;

    Aplique a Função de Aceitação;

    Atualize o Espaço de Crença (fontes de conhecimento) usando os *nAceitos* anticorpos da população;

    Aplique a Função de Influência Principal;

#### **Fim Enquanto**

---

O Espaço de Crença é utilizado para extrair informações dos anticorpos da população (informações que serão utilizadas na atualização dos conhecimentos). O Espaço de Crença utiliza estes conhecimentos como um guia para gerar novos indivíduos durante o processo de

hipermutação através das funções de influência, isto é, os operadores de hipermutação são modificados pelas funções de influência.

Diferente do sistema Imune Cultural, o algoritmo Imune *Fuzzy* Cultural foi testado de duas maneiras: utilizando o método de reparação (detalhado no algoritmo 4) e um método de penalidade. A penalidade é utilizada nos indivíduos que foram gerados com valores inactíveis e, nesse caso, o algoritmo de reparação não é executado. O cálculo da penalidade é dada por

$$Penalidade = Q * Abs(P_t - P_d), \quad (12)$$

onde  $Q$  é uma variável fixa,  $P_t$  é a potência total gerada pela solução e  $P_d$  é a potência desejada. Foram testados vários valores para  $Q$  (no intervalo de 0,2 até 1500) e os melhores obtidos foram para  $Q = 0,5$  e  $Q = 2$ . No capítulo 7 são apresentados os resultados utilizando tanto o método de reparação quanto o método de penalidade.

### 6.2.1 Protocolos de Comunicação: Funções de Aceitação e Influência

Os protocolos de comunicação são os componentes que determinam quais anticorpos são considerados durante a atualização do Espaço de Crença (por meio da Função de Aceitação) e como um conhecimento armazenado no Espaço de Crença influencia o operador de hipermutação (através da Função de Influência).

#### Função de Aceitação

Neste trabalho uma Função de Aceitação dinâmica inspirada nos trabalhos de Iacoban, Reynolds e Brewster (2003) e Reynolds e Peng (2005) é utilizada, a qual é definida na Equação 13.

$$nAceitos = tamPop * \left( aceites_{perc} + \frac{aceitos_{perc}}{gen} \right), \quad (13)$$

onde  $nAceitos$  é o número de melhores anticorpos da população que serão utilizados para atualizar as fontes de conhecimentos,  $tamPop$  é o número de anticorpos na população,  $aceitos_{perc}$  é um parâmetro que determina a porcentagem de anticorpos aceitos e  $gen$  é a geração atual. Esta função de aceitação permite que muitos anticorpos contribuam para a atualização durante o início da evolução (onde pouco conhecimento está acumulado) e que poucos anticorpos sejam aceitos no final da evolução (onde uma grande quantidade de conhecimento já foi adquirido).

#### Função de Influência Dinâmica

A função de influência principal é responsável pela escolha da fonte de conhecimento que irá influenciar os operadores de hipermutação. O trabalho original no qual essa dissertação é baseada (GONÇALVES et al., 2007) utiliza o método da roleta (*Roulette Wheel* (BECERRA; COELLO, 2006)) para determinar a quantidade exata de cada conhecimento a ser utilizado. No início da evolução, todas as fontes de conhecimentos possuem a mesma probabilidade de serem aplicadas (25%). Durante o processo de evolução, a probabilidade da  $i$ -ésima fonte de conhecimento influenciar o operador de hipermutação é dada pela Equação 14.

$$probKS_k = 0,1 + 0,6 * \left( \frac{ant_{gbKS_k}}{tamPop} \right), \quad (14)$$

onde  $probKS_k$  é a probabilidade de selecionar a  $k$ -ésima fonte de conhecimento para influenciar o operador de hipermutação,  $ant_{gbKS_k}$  é o número de anticorpos que foram gerados pela influência do  $k$ -ésimo conhecimento e  $tamPop$  é o tamanho da população. A Equação 14 favorece a aplicação das fontes de conhecimento que são capazes de manter seus anticorpos gerados na população e garante que cada conhecimento possui ao menos 10% de chance de ser aplicado.

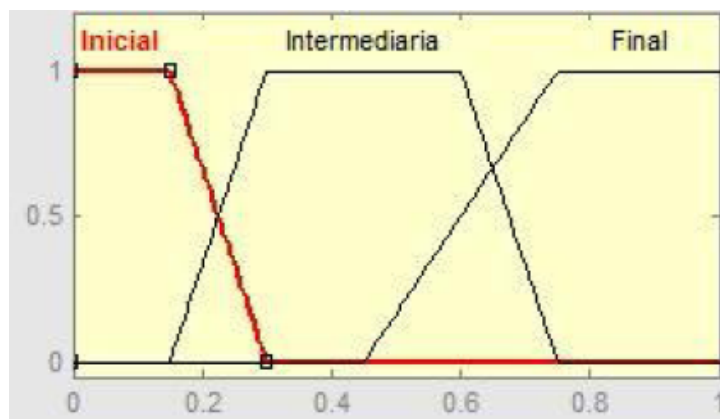
#### Função de Influência *Fuzzy*

A função de influência principal utilizada na versão Imune Cultural foi modificada neste trabalho sendo transformada em uma Função de Influência *Fuzzy*, com base em Sistemas de

Inferência *Fuzzy* (SIF). Foram desenvolvidos quatro SIF (um para cada conhecimento - Situacional, Normativo, Topográfico e Histórico). Assim como na versão Imune Cultural, na variante *fuzzy*, o método da roleta (*Roulette Wheel* (BECERRA; COELLO, 2006)) também é usado para determinar a quantidade exata de cada conhecimento a ser utilizado. A diferença se dá no cálculo da probabilidade de cada conhecimento: na versão Imune Cultural este cálculo é feito com base na equação 14, enquanto que na versão Imune *Fuzzy* Cultural este cálculo é feito por meio de quatro SIFs, um para cada conhecimento. Um ponto em comum entre as funções de influência (dinâmica e *fuzzy*) é a garantia de que cada conhecimento atua pelo menos em 10% da população.

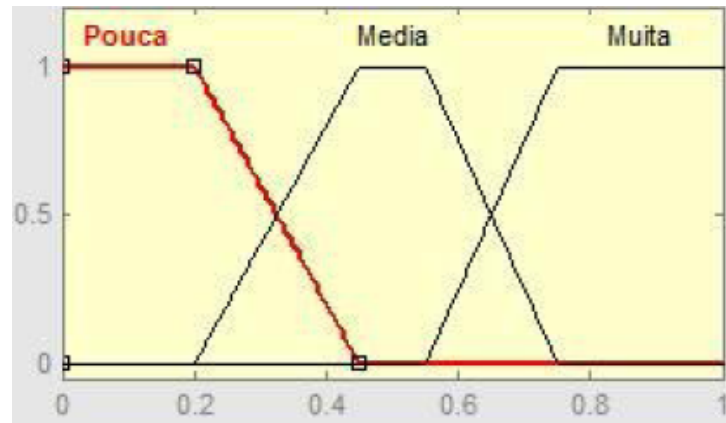
Os SIFs desenvolvidos neste trabalho fazem uso das seguintes características:

1. *Variáveis de entrada*: as variáveis de entrada foram normalizadas para assumirem apenas valores entre 0 e 1. Assim os seus universos de discursos estão compreendidos no intervalo (0,1).
  - **Idade**: representa a idade da população de indivíduos, e os termos associados a ela são: Inicial, Intermediária e Final. Nos quatro SIFs, a variável Idade recebe os mesmos valores, observados na Figura 15;




**Figura 15: Partição do Universo de discurso da variável Idade**  
Fonte: Autoria própria.

- **Diversidade:** a diversidade da população representa quão diferentes os indivíduos são. O conjunto de termos associados a essa variável é: Pouca, Média e Muita. A Figura 16 mostra a partição universo para a variável Diversidade;




**Figura 16: Partição do Universo de discurso da variável Diversidade.**  
**Fonte: Autoria própria.**

- **Qualidade:** representa a qualidade do conhecimento, a quantidade de bons indivíduos que o conhecimento é capaz de gerar. O conjunto de termos associados a essa variável é: Baixa, Média e Alta. A Figura 17 mostra a partição universo para essa variável.



**Figura 17: Partição do Universo de discurso da variável Qualidade.**  
**Fonte: Autoria própria.**


2. *Base de regras*: existem quatro bases de regras (uma para cada SIF), com 27 (vinte e sete) regras cada (somando um total de 108 regras). A Figura 18 apresenta como exemplo o modelo da base de dados do Conhecimento Topográfico;



**Figura 18: Conjunto de regras do Sistema de Inferência *Fuzzy* para o Conhecimento Topográfico:** As linhas representam as regras (num total de 27) e as colunas representam as funções de pertinência dos antecedentes (Idade, Diversidade e Qualidade) e do consequente de cada regra.

Fonte: Autoria própria.

3. *Variável de Saída*: a variável de saída do  $k$ -ésimo SIF, resulta na probabilidade de selecionar a  $k$ -ésima fonte de conhecimento para influenciar o operador de hipermutação. A Figura 19 exemplifica a saída para o Conhecimento Situacional;
4. *Mecanismo de Raciocínio*: foram utilizados os seguintes operadores para o Sistema de Inferência *Fuzzy*, do tipo Mamdani:



**Figura 19: Partição do Universo da variável AplicarSituacional.**

**Fonte: Autoria própria.**

- **Agregação dos Antecedentes:** produto algébrico;
- **Semântica da Regra:** mínimo (Regra de Mamdani);
- **Agregação das Regras:** máximo;
- **Método de Defuzzificação:** centróide.

A escolha das funções trapezoidais foi no sentido de manter o sistema com um comportamento uniforme por intervalos maiores das variáveis consideradas. Entretanto nenhum teste com outros tipos de funções foi realizado. Mais detalhes dos quatro SIFs podem ser vistos no Apêndice B.

A base de regra é definida com o intuito de definir qual o melhor momento de se utilizar determinado conhecimento. Quando a geração está no início, a idade é pequena e a diversidade é grande, os conhecimentos não possuem muita informação. Neste caso utiliza-se mais o conhecimento topográfico que dá uma visão geral do espaço de busca. Quando a geração está em uma idade intermediária e já possui uma diversidade média, é interessante que haja um balanceamento entre os indivíduos para não aumentar demais a diversidade e também para não deixar de intensificar a busca, utilizando todos os tipos de conhecimento (SALEEM, 2001)(REYNOLDS; PENG, 2005). No final os conhecimentos situacional e normativo são mais aplicados como forma de fazer buscas mais localizadas em boas regiões já encontradas anteriormente.

Para a implementação do Sistema de Inferência *Fuzzy* foi utilizado um pacote Java, que fornece uma *engine*, ou seja, um motor de inferência *Fuzzy*<sup>1</sup>. As imagens do SIF foram geradas no *software* Matlab, da Mathworks.

### 6.2.2 Tipos de Conhecimento

Neste trabalho foram utilizados 4 conhecimentos, descritos nas seções a seguir.

### 6.2.3 Conhecimento Situacional

O Conhecimento Situacional armazena os *pMelhores* anticorpos encontrados durante o processo evolucionário (BECERRA; COELLO, 2006).

A atualização do conhecimento Situacional ocorre quando um novo indivíduo é aceito e o mesmo é melhor que o pior indivíduo armazenado no conhecimento, então o pior indivíduo é eliminado e o novo indivíduo é adicionado.

Os anticorpos armazenados são utilizados como líderes para influenciar os operadores de hipermutação. Esta influência é similar a operação de hipermutação apresentada na Equação 10 mas o termo  $ant_{ij}$  do lado direito é substituído pelo termo  $melhor_{kj}$ , onde  $melhor_{kj}$  é o  $j$ -ésimo componente do  $k$ -ésimo melhor anticorpo armazenado no Conhecimento Situacional, e  $k$  é um índice aleatório selecionado entre os melhores indivíduos. A Equação 15 descreve a hipermutação, utilizada pelo Conhecimento Situacional, tal que

$$ant_{i,j}^h = melhor_{k,j} + mult * (Cost_i / MinCost_{gen} * R(0, 1) * (P_j^{max} - P_j^{min})). \quad (15)$$

### 6.2.4 Conhecimento Normativo

O Conhecimento Normativo contém os intervalos para as saídas das unidades geradoras onde boas soluções têm sido encontradas. Ele é utilizado para mover as saídas das novas

---

<sup>1</sup><http://www.intelligent-systems.info/FuzzyEngine.htm>



soluções em direção a estes intervalos. Os intervalos do Conhecimento Normativo são inicializados com o limite inferior e superior das saídas dos geradores (definidas pelas restrições de operação de cada gerador).

A atualização do Conhecimento Normativo pode reduzir ou expandir o intervalo armazenado. Uma expansão ocorre quando indivíduos aceitos não fazem parte do intervalo, enquanto que uma redução ocorre quando todos os indivíduos aceitos estão dentro do intervalo. Os novos valores das extremidades são definidos pelos indivíduos com melhores custos de combustível. É importante salientar que os limites do Conhecimento Normativo não podem violar as restrições operacionais.

A influência do Conhecimento Normativo é dada pela Equação 16.

$$ant_{i,j}^h = \begin{cases} ant_{i,j} + mult * (Cost_i / MinCost_{gen}) * Abs(R(0,1) * (NL_j - Nl_j)), & \text{se } ant_{i,j} < NL_j \\ ant_{i,j} - mult * (Cost_i / MinCost_{gen}) * Abs(R(0,1) * (NL_j - Nl_j)), & \text{se } ant_{i,j} > NL_j \\ ant_{i,j} + mult * (Cost_i / MinCost_{gen}) * R(0,1) * (NL_j - Nl_j), & \text{caso contrário.} \end{cases} \quad (16)$$

A equação anterior é a alteração da Equação 10 para o Conhecimento Normativo, onde  $NL_j$  e  $Nl_j$  são, respectivamente, os limites inferiores e superiores do intervalo normativo associado ao  $j$ -ésimo componente,  $Abs()$  é uma função que retorna o valor absoluto de seu argumento e os outros termos são definidos na Equação 10. Esta função de influência é adaptativa: ela é intensiva quando o intervalo normativo é grande (o intervalo bom é incerto) e ela é suave quando o intervalo normativo é pequeno (intervalo se aproxima do bom).

### 6.2.5 Conhecimento Histórico

Este conhecimento armazena uma lista de melhores anticorpos encontrados antes da última janela de mudança no ambiente. Ele também armazena a média das direções e distância das

alterações para cada componente entre as alterações ambientais. Nesse trabalho como não ocorrem mudanças no ambiente, este conhecimento é adaptado e ele é atualizado quando o algoritmo cai em um mínimo local (onde não ocorre mudança no melhor anticorpo encontrado durante as últimas  $p$  gerações).

A função de influência do Conhecimento Histórico utilizada nesse trabalho é dada pela Equação 17:

$$ant_{i,j}^h = \begin{cases} ant_{i,j} + mult * (Cost_i / MinCost_{gen}) * Abs(R(0,1) * (distMedia_j)), & \text{se } dirMedia_j \geq 0 \\ ant_{i,j} - mult * (Cost_i / MinCost_{gen}) * Abs(R(0,1) * (distMedia_j)), & \text{se } dirMedia_j < 0; \end{cases} \quad (17)$$

onde  $mediaDist_j$  é a distância média da mudança no  $j$ -ésimo componente,  $dirMedia_j$  é a direção média da mudança no  $j$ -ésimo componente (ambas fornecidas pelas Equações 18 e 19) e os demais termos já foram previamente definidos.


$$distMedia_j = \left\{ \left( \sum_{i=1}^{tamJanela-1} Abs(HistMelhor_{i+1,j} - HistMelhor_{i,j}) \right) / (tamJanela - 1) \right. \quad (18)$$

$$dirMedia_j = \left\{ \left( \sum_{i=1}^{tamJanela-1} Sinal(HistMelhor_{i+1,j} - HistMelhor_{i,j}) \right), \quad (19)$$

onde  $tamJanela$  é o número de anticorpos armazenados no Conhecimento Histórico,  $HistMelhor$  é o  $j$ -ésimo componente do melhor indivíduo armazenado e  $Sinal()$  é a função que retorna +1 se o argumento é positivo, -1 se o argumento é negativo e 0, caso contrário. Esta influência tenta incrementar o  $j$ -ésimo componente do anticorpo submetido a hipermutação, se em média o  $j$ -ésimo componente do melhor anticorpo for maior ou igual que o  $j$ -ésimo componente do melhor anticorpo no evento anterior e tenta decrementar este componente, caso contrário. Nos

dois casos a hipermutação é proporcional à média da distância observada entre as mudanças.

A Figura 20 apresenta um exemplo do funcionamento do Conhecimento Histórico. É possível observar que de um evento para outro ( $G$  representa geração atual, então  $G20$  representa a vigésima geração) são armazenadas a distância e a direção. No caso de cair em um mínimo local, é possível saber quais os passos (distância e direção seguidas) para sair do mesmo.



**Figura 20: Representação do Conhecimento Histórico**

Fonte: Autoria própria.

#### 6.2.6 Conhecimento Topográfico

O Conhecimento Topográfico é usado para criar um mapa do *fitness* do problema durante o processo evolutivo. Ele consiste de um conjunto de regiões e o melhor indivíduo encontrado em cada região. Ele também armazena uma lista ordenada das  $r$  melhores regiões (as quais são classificadas de acordo com os melhores indivíduos). A região é representada como um nó em uma árvore binária e armazena os limites inferiores e superiores para cada componente e o melhor anticorpo encontrado até o momento em cada região.

A árvore binária é inicializada com um nó raiz que representa todo o espaço possível e possui o melhor anticorpo da primeira geração. Se durante a atualização do Conhecimento Topográfico um anticorpo com um melhor custo de combustível (maior afinidade) que o melhor

anticorpo representado na região é aceito, e este anticorpo pertencer a esta região, então o nó é dividido (a região é dividida em duas). O componente onde a divisão ocorre é o componente que possui a maior diferença entre o melhor anticorpo anterior da região e o novo. A divisão é feita na metade da distância entre o valor do componente novo e o antigo melhor indivíduo da região, conforme equação 20, tal que

$$PontoDivisao = \begin{cases} Novo_j + (Ant_j - Novo_j)/2, \\ \text{se } Old_j \geq Novo_j \\ Ant_j + (Novo_j - Ant_j)/2, \\ \text{caso contrário} \end{cases} \quad (20)$$

onde *PontoDivisao* é o valor do *j*-ésimo componente onde a região será dividida, *Ant<sub>j</sub>* é o *j*-ésimo componente do melhor anticorpo anterior da célula a ser dividida e *Novo<sub>j</sub>* é o *j*-ésimo componente do novo melhor indivíduo encontrado nesta célula.

A função de influência do Conhecimento Topográfico é descrita pela Equação 21, tal que

$$ant_{i,j}^h = ant_{i,j} + mult * (Cost_i / MinCost_{gen}) * R(0,1) * (R_{k,j}^{sup} - R_{k,j}^{inf}) \quad (21)$$

onde  $R_{k,j}^{sup}$  e  $R_{k,j}^{inf}$  são os limites superior e inferior do *j*-ésimo componente na *k*-ésima região onde *k* é selecionado aleatoriamente de acordo com a afinidade do melhor anticorpo de cada região se um número aleatório uniforme no intervalo [0,1] for menor que *pElite* (probabilidade das melhores regiões serem escolhidas mais frequentemente) e caso contrário é selecionado aleatoriamente e independentemente da afinidade. Esta função de influência tende a explorar boas regiões do espaço de busca.

## 7 SIMULAÇÕES E RESULTADOS

Neste capítulo, os resultados de uma série de experimentos considerando o problema do despacho econômico serão mostrados e analisados.

### 7.1 DESCRIÇÃO DOS EXPERIMENTOS

Na primeira parte dos experimentos (seção 7.2) o objetivo é avaliar se as abordagens híbridas superam suas versões mais puras, ou seja, se a inclusão do algoritmo cultural traz ganho sobre a versão não-cultural e se o uso de Sistema de Inferência *Fuzzy* traz ou não ganho para a versão cultural imune. Pretende-se ainda avaliar se a metodologia de reparação é mais eficiente do que a metodologia de penalidade considerando-se as restrições impostas pelo problema do despacho econômico. Neste caso, o problema consiste na minimização dos custos de produção de energia e todas as técnicas avaliadas serão aplicadas aos três casos de estudo extraídos da literatura (três instâncias do problema do despacho econômico):

- Caso de 13 geradores com demanda de 1800 MW(COELHO; MARIANI, 2006);
- Caso de 13 geradores com demanda de 2520 MW(KHAMSAWANG; POTHIIYA; BOON-SENG, 2004);
- Caso de 40 geradores com demanda de 10500 MW(COELHO; MARIANI, 2006).

No processo de avaliação das diferentes abordagens propostas, será considerado um teste estatístico, o Bootstrap (EFRON; TIBSHIRANI, 1993). Este teste assume apenas que as amostras

são independentes, então serão obtidos e comparados os intervalos de confiança para a média, assumindo-se que se não há intersecção entre os intervalos os dados são significativamente diferentes.

Na segunda parte dos experimentos (seção 7.3), o conjunto de experimentos que obtiver os melhores resultados terá suas abordagens comparadas com outras técnicas da literatura, novamente para as três instâncias do problema do despacho citadas anteriormente.

## 7.2 COMPARAÇÃO ENTRE AS DIFERENTES ABORDAGENS BASEADAS EM SIA

Nesta seção, serão consideradas quatro metodologias distintas:

1. Sistema Imunológico Artificial puro ( IS);
2. Sistema Imunológico Artificial com Algoritmo Cultural ( CIS);
3. Sistema Imunológico Artificial com Algoritmo Cultural e função de Influência Fuzzy ( FCIS):
  - FCIS com função de penalidade ( FCISp);
  - FCIS com função de reparação ( FCISr).

Em todos os testes foi utilizado o seguinte conjunto de parâmetros, os quais foram obtidos após uma série de testes:

1. Critério de parada igual a 3000 gerações;
2.  $dup$  igual a 4 (operador de clonagem estático);
3. Número de regiões de elite no conhecimento topográfico igual a 40;
4.  $tau_B$  igual a 100 gerações (operador de *aging*);
5. Número de melhores indivíduos do Conhecimento Situacional ( $pMelhores$ ) armazenados igual a 10;

6. Tamanho de janela do Conhecimento Histórico (*tamanhoJanela*) igual a 10;
7. Limite para considerar mínimo local no Conhecimento Histórico  $p$  igual a 200;
8. Taxa de indivíduos aceitos (*aceitos<sub>perc</sub>*) igual a 0,2;
9. Probabilidade inicial de influência de 25% para cada conhecimento (Situacional, Normativo, Topográfico e Histórico).

É importante salientar que este conjunto de parâmetros permaneceu fixo durante todos os experimentos (exceto tamanho da população).

Para cada metodologia serão apresentados dois conjuntos de experimentos. Apenas o tamanho da população irá variar de um conjunto de experimentos para outro. Os resultados apresentam o melhor custo, a média de custos, o pior custo, o desvio padrão ( $\sigma$ ) e o tempo computacional<sup>1</sup> (em minutos).

#### 7.2.1 Despacho Econômico: 13 geradores e demanda de 1800 MW

Nesta seção serão mostrados os resultados de dois grupos de experimentos: no primeiro grupo assume-se uma população formada 50 indivíduos (anticorpos) e no segundo grupo este parâmetro é alterado para 100 indivíduos. Em ambos os grupos, o problema considerado será o de 13 geradores com demanda de 1800 MW.

#### População com 50 indivíduos

A Tabela 2 mostra os resultados obtidos para cada abordagem após a execução de 50 execuções independentes<sup>2</sup>.

---

<sup>1</sup>Tempo médio para 50 simulações para se alcançar a condição de parada. A configuração utilizada para a obtenção dos tempos computacionais foi: notebook Toshiba A135 com 2GB de memória, processador *dual-core* 1.73GHz, sistema operacional Ubuntu 9.04 e Netbeans 6.5.

<sup>2</sup>Em cada simulação a semente do gerador aleatório é alterada de forma a gerar uma população inicial diferente.

**Tabela 2: Resultados obtidos com 50 indivíduos na população: 13 geradores e demanda de 1800 MW**

Técnica	IS (1)	CIS (2)	FCISp (3)	FCISr (4)
Melhor Custo	17969,27	<b>17961,56</b>	17996,61	17969,52
Média	17977,66	17971,47	18073,62	<b>17971,13</b>
Pior Custo	18074,22	17987,20	18182,44	<b>17986,26</b>
$\sigma$	18,84	3,50	44,66	<b>2,80</b>
Tempo (seg)	26.94	27.08	<b>24.48</b>	36.9

Fonte: Autoria própria.

A Tabela 2 mostrou que a versão imune *fuzzy* cultural com reparação (FCISr) apresentou ligeira vantagem em termos de média em relação às demais (com menor desvio padrão) e que o melhor resultado (menor custo) foi alcançado pela versão imune cultural (CIS).

População com 100 indivíduos

A Tabela 3 mostra os resultados obtidos para cada abordagem após a execução de 50 execuções independentes.

**Tabela 3: Resultados obtidos com 100 indivíduos na população: 13 Geradores e demanda de 1800 MW**

Técnica	IS (1)	CIS (2)	FCISp (3)	FCISr (4)
Melhor Custo	17969,42	17961,43	17978,89	<b>17961,38</b>
Média	17972,33	<b>17970,16</b>	18082,06	17970,26
Pior Custo	17986,48	<b>17971,64</b>	18241,75	17977,73
$\sigma$	5,71	<b>1,37</b>	50,23	2,02
Tempo (seg)	37.88	<b>33.08</b>	33.86	57.22

Fonte: Autoria própria.

Além disso, esta tabela mostra que desta vez a versão imune cultural (CIS) apresentou ligeira vantagem em termos de média em relação às demais, com menor desvio padrão na média. A versão imune *fuzzy* cultural com reparação (FCISr) apresentou uma vantagem mínima em termos de menor custo.



### 7.2.2 Despacho Econômico: 13 geradores e demanda de 2520 MW

Nesta seção, também serão mostrados os resultados de dois grupos de experimentos: um com 50 e outro 100 indivíduos na população. Em ambos os grupos, o problema considerado será o de 13 geradores com demanda de 2520 MW.

#### População com 50 indivíduos

A Tabela 4 mostra os resultados obtidos para cada abordagem após a execução de 50 execuções independentes.

**Tabela 4: Resultados obtidos com 50 indivíduos na população: 13 Geradores e demanda de 2520 MW**

Técnica	IS (1)	CIS (2)	FCISp (3)	FCISr (4)
Melhor Custo	<b>24170,65</b>	24171,07	24172,00	24170,83
Média	24209,06	<b>24183,15</b>	24329,67	24186,55
Pior Custo	24288,78	<b>24251,16</b>	24635,01	24289,55
$\sigma$	45,41	<b>20,48</b>	112,75	26,26
Tempo (seg)	53.36	<b>40.84</b>	41.26	54.28

**Fonte: Autoria própria.**

A Tabela 4 mostra que a versão imune cultural (CIS) apresentou vantagem em termos de média e desvio padrão em relação às demais versões. O melhor resultado (menor custo) foi alcançado pela versão imune puro (IS) mas com diferença mínima para as demais versões.

#### População com 100 indivíduos

A Tabela 5 mostra os resultados obtidos para cada abordagem após a execução de 50 execuções independentes.

A Tabela 5 mostra que a versão imune cultural (CIS) apresentou vantagem em termos de média e desvio padrão em relação às demais. O melhor resultado (menor custo) foi alcançado pela versão imune (IS), novamente com uma diferença mínima para as outras versões propostas.

**Tabela 5: Resultados obtidos com 100 indivíduos na população: 13 Geradores e demanda de 2520 MW**

Técnica	IS (1)	CIS (2)	FCISp (3)	FCISr (4)
Melhor Custo	<b>24170,44</b>	24170,79	24176,35	24171,17
Média	24191,13	<b>24174,09</b>	24305,82	24177,14
Pior Custo	24289,00	<b>24217,36</b>	24511,66	24282,05
$\sigma$	34,05	<b>6,69</b>	91,77	16,86
Tempo (seg)	68.44	50.94	<b>44.04</b>	84.74

Fonte: Autoria própria.

### 7.2.3 Despacho Econômico: 40 geradores e demanda de 10500 MW

Novamente, serão mostrados os resultados de dois grupos de experimentos: um com 50 e outro 100 indivíduos na população. Em ambos os grupos, o problema considerado será o de 40 geradores com demanda de 10500 MW.

#### População com 50 indivíduos

A Tabela 6 mostra os resultados obtidos para cada abordagem após a execução de 50 execuções independentes.

**Tabela 6: Resultados obtidos com 50 indivíduos na população: 40 Geradores e demanda de 10500 MW**

Técnica	IS (1)	CIS (2)	FCISp (3)	FCISr (4)
Melhor Custo	121476,27	121522,77	121534,78	<b>121463,54</b>
Média	121787,59	121805,27	121902,08	<b>121640,09</b>
Pior Custo	122191,38	122525,40	122555,62	<b>121842,24</b>
$\sigma$	146,04	210,08	261,97	<b>121,43</b>
Tempo (seg)	<b>153.08</b>	326.78	182.32	238.78

Fonte: Autoria própria.

A Tabela 6 mostra que a versão imune *fuzzy* cultural com reparação (FCISr) apresentou vantagem em termos de média (com o menor desvio padrão) e menor custo (melhor resultado) em relação às demais versões propostas.

População com 100 indivíduos

A Tabela 7 mostra os resultados obtidos para cada abordagem após a execução de 50 execuções independentes.

**Tabela 7: Resultados obtidos com 100 indivíduos na população: 40 Geradores e demanda de 10500 MW**

Técnica	IS (1)	CIS (2)	FCISp (3)	FCISr (4)
Melhor Custo	121496,69	121528,31	121516,54	<b>121455,93</b>
Média	121742,69	121744,08	121828,80	<b>121630,36</b>
Pior Custo	122157,34	122707,88	122512,77	<b>121981,77</b>
$\sigma$	<b>114,48</b>	212,06	234,76	132,84
Tempo (seg)	<b>193.40</b>	372.72	199.66	372.02

**Fonte: Autoria própria.**

Pela análise da Tabela 7 pode-se dizer que a versão com influência *fuzzy* e reparação (FCISr) apresentou vantagem em termos de média e melhor resultado (menor custo) em relação às demais versões. O menor desvio padrão foi obtido pelo sistema imune puro (IS).

#### 7.2.4 Análise Estatística

Para fazer a análise estatística, utilizaremos apenas as abordagens com 100 indivíduos, pois as mesmas obtiveram melhores resultados. O teste de Bootstrap utilizado tem uma confiabilidade de 95% em seus resultados.

13 geradores e demanda de 1800 MW

Para o problema de 13 geradores e demanda de 1800 MW, o intervalo de confiança para cada um dos métodos foi:

- IS = [17971.197400 - 17973.925400];
- CIS = [17969.632600 - 17970.375800];
- FCISp = [18070.515000 - 18093.743600];

- FCISr = [17969.811600 - 17970.750600].

Fazendo análise dos intervalos acima, é possível observar que os métodos CIS e FCISr têm desempenhos semelhantes (não há como afirmar qual abordagem é melhor). O método FCISp pode ser considerado o pior, visto que não existe intersecção entre ele e os demais métodos e os valores de seu intervalo estão acima dos demais. O IS também é considerado diferente, pois não tem intersecção com nenhum outro método. É possível observar que o acréscimo do algoritmo cultural ao sistema imune trouxe melhorias para o mesmo.

### 13 geradores e demanda de 2520 MW

O intervalo de confiança para cada um dos métodos, para o problema de 13 geradores e demanda de 2520 MW, foi:

- IS = [24183.918400 - 24200.022600];
- CIS = [24173.835200 - 24177.685200];
- FCISp = [24286.339000 - 24329.206800];
- FCISr = [24174.565400 - 24184.498600].

Nesse caso o único método comprovadamente diferente dos demais é o FCISp, visto que não existe intersecção entre o seu intervalo de confiança e dos outros. O CIS pode ser considerado superior ao IS, pois não possui intersecção com o mesmo. Já o desempenho do FCISr é semelhante ao CIS (não há como afirmar qual dos dois é melhor). Novamente é possível observar que os algoritmos culturais trouxeram melhorias ao sistema imune puro.

### 40 geradores e demanda de 10500 MW

Com demanda de 10500 MW e número de geradores igual a 40, o intervalo de confiança para cada um dos métodos foi:

- IS = [121717.563200 - 121770.893600];
- CIS = [121704.006000 - 121802.952000];
- FCISp = [121775.898800 - 121882.469800];
- FCISr = [121600.279200 - 121661.314200].

Analisando os intervalos é possível observar que o método FCISr é diferente dos demais, e como seus valores estão abaixo dos demais intervalos, ele pode ser considerado o melhor. O método IS é estatisticamente diferente do FCISp, visto que não existe intersecção em nenhum ponto entre eles. Os métodos IS e CIS têm desempenhos semelhantes (não é possível dizer qual dentre eles é melhor).

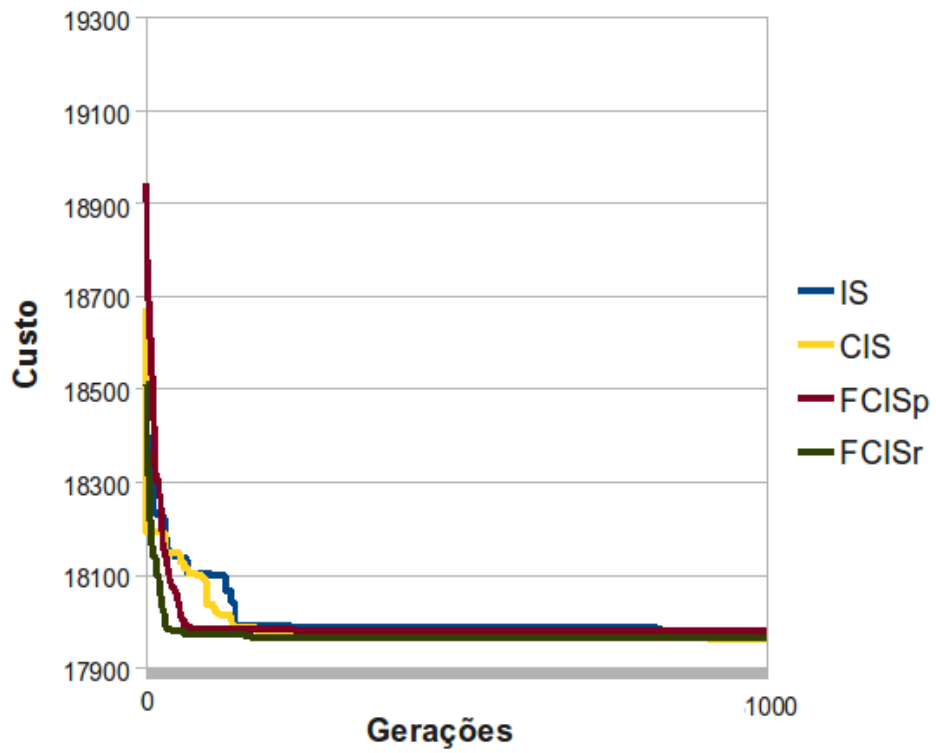
Com base na análise anterior, e considerando a população de 100 indivíduos, é possível notar que o FCISr (utilizando um mesmo conjunto de parâmetros) teve bom desempenho em todas as instâncias analisadas. Já o método de penalidade trouxe perda de desempenho para o sistema imune *fuzzy* cultural, visto que em todas as instâncias o mesmo foi estatisticamente inferior. Nas instâncias de 13 geradores (1800 e 2520 MW) o CIS e o FCISr tiveram desempenhos semelhantes, mas para a instância de 40 geradores o FCISr superou os demais.

### 7.2.5 Ilustração da convergência dos métodos

Nessa seção são apresentados os gráficos de convergência para todos os métodos propostos.

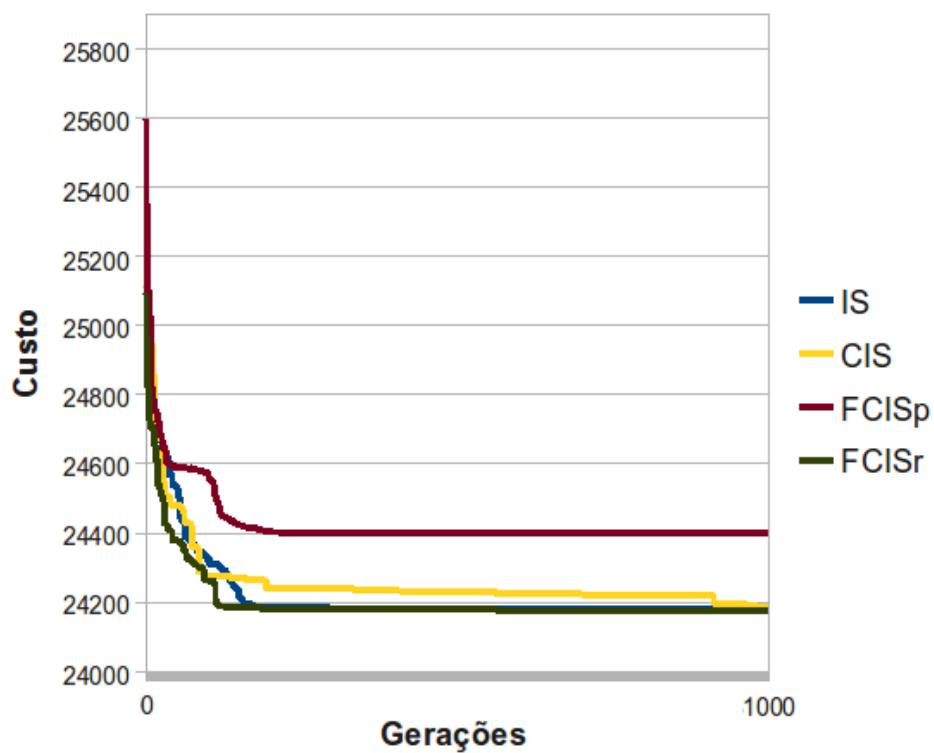
#### Convergência dos melhores indivíduos

As Figuras 21, 22 e 23 apresentam a evolução do *fitness* do melhor indivíduo ao longo das 1000 primeiras gerações para as simulações que geraram os melhores resultados pelos métodos IS, CIS, FCISp e FCISr (os melhores resultados foram obtidos com os métodos com 100 indivíduos).



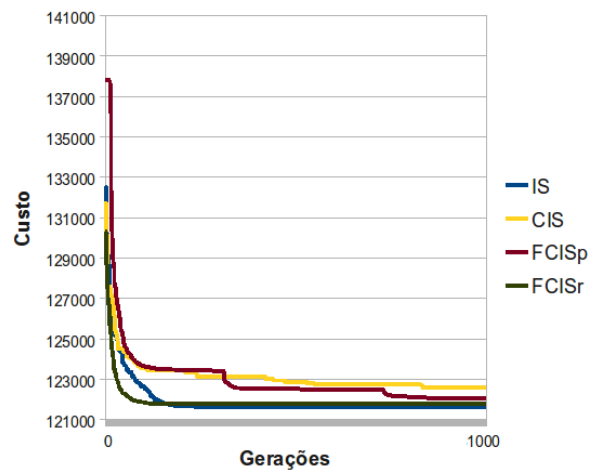
**Figura 21:** Convergência dos melhores indivíduos, dos métodos propostos, para demanda de 1800 MW e 13 geradores

Fonte: Autoria própria.



**Figura 22: Convergência dos melhores indivíduos, dos métodos propostos, para demanda de 2520 MW e 13 geradores**

**Fonte: Autoria própria.**



**Figura 23: Convergência dos melhores indivíduos, dos métodos propostos, para demanda de 10500 MW e 40 geradores**

**Fonte: Autoria própria.**


#### Convergência média dos indivíduos

As Figuras 24, 25 e 26 apresentam a evolução do *fitness* médio dos indivíduos da população ao longo das 1000 primeiras gerações para as simulações que geraram os melhores resultados pelos métodos IS, CIS, FCISp e FCISr (são as mesmas simulações que geraram os gráficos do comportamento dos melhores indivíduos para cada método, mas agora avaliando a média do *fitness* da população).

#### 7.2.6 Melhores indivíduos

As Tabelas 8, 9 e 10 apresentam os valores de cada gerador para os melhores resultados obtidos nos casos de 13 geradores e 1800 MW de demanda, 13 geradores e demanda de 2520 MW e, 40 geradores com demanda de 10500 MW.





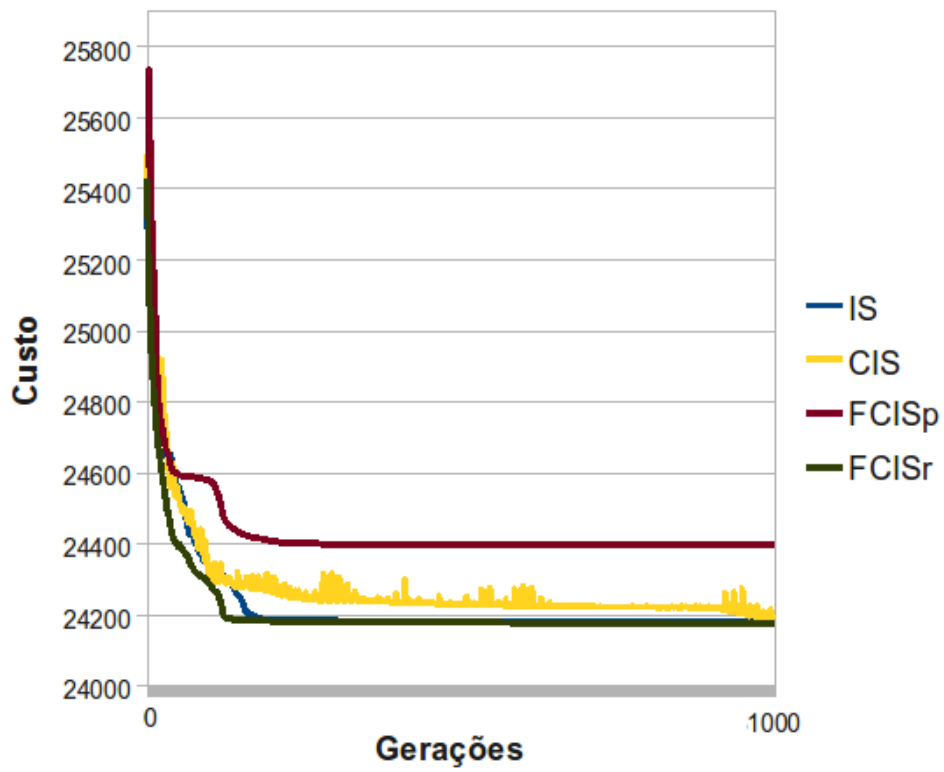
**Figura 24:** Convergência média dos indivíduos, dos métodos propostos, para demanda de 1800 MW e 13 geradores

**Fonte:** Autoria própria.

**Tabela 8:** Valor dos geradores para o melhor resultado obtido para demanda de 1800MW e 13 geradores (método FCISr com 100 indivíduos).


<b>Gerador</b>	<b>Potência</b>
$P_1$	628.2695
$P_2$	149.5691
$P_3$	223.0717
$P_4$	109.8351
$P_5$	109.8592
$P_6$	109.8357
$P_7$	60.0000
$P_8$	109.8345
$P_9$	109.7252
$P_{10}$	40.0000
$P_{11}$	40.0000
$P_{12}$	55.0000
$P_{13}$	55.0000
$\sum_{j=1}^{13} P_i$	1800.0000

**Fonte:** Autoria própria.



**Figura 25:** Convergência média dos indivíduos, dos métodos propostos, para demanda de 2520 MW e 13 geradores

**Fonte:** Autoria própria.



**Figura 26:** Convergência média dos indivíduos, dos métodos propostos, para demanda de 10500 MW e 40 geradores

Fonte: Autoria própria.

**Tabela 9: Valor dos geradores para o melhor resultado obtido para demanda de 2520MW e 13 geradores (método IS com 100 indivíduos).**

<b>Gerador</b>	<b>Potência</b>
$P_1$	628.2761
$P_2$	299.1912
$P_3$	299.1522
$P_4$	159.7234
$P_5$	159.7257
$P_6$	159.7116
$P_7$	159.7064
$P_8$	159.7021
$P_9$	159.7275
$P_{10}$	77.3225
$P_{11}$	77.3212
$P_{12}$	88.0517
$P_{13}$	92.3886
$\sum_{j=1}^{13} P_i$	2520.0000

**Fonte: Autoria própria.**

### 7.3 COMPARAÇÃO COM OUTROS MÉTODOS DA LITERATURA

Os melhores resultados (menores custos) produzidos pelos métodos propostos nesta dissertação foram comparados com outras abordagens do estado-da-arte, citadas nos itens abaixo. Importante salientar que, com base nos testes estatísticos da Seção 7.2.4, o método FCISp não será comparados com as demais abordagens, visto que o mesmo obteve um desempenho comprovadamente pior que as demais abordagens propostas nesta dissertação.

- DEC-SQP (*Differential Evolution Chaotic with Sequential Quadratic Programming*) proposto por Coelho e Mariani (2006);
- IGA (*Improved Genetic Algorithm*) proposto por Ling et al. (2003);
- MPSO (*Modified Particle Swarm Optimization*) proposto por Hou et al. (2005).
- SDE (*Self-adaptive Differential Evolution*) proposto por Balamurugan e Subramanian

**Tabela 10: Valor dos geradores para o melhor resultado obtido para demanda de 10500MW e 40 geradores (método FCISr com 100 indivíduos).**

<b>Gerador</b>	<b>Potência</b>
$P_1$	110.8018
$P_2$	110.9537
$P_3$	97.3930
$P_4$	179.7339
$P_5$	88.0905
$P_6$	139.9986
$P_7$	299.9849
$P_8$	284.6969
$P_9$	284.6549
$P_{10}$	130.0000
$P_{11}$	94.0003
$P_{12}$	94.0026
$P_{13}$	214.7654
$P_{14}$	394.2881
$P_{15}$	304.5446
$P_{16}$	394.2813
$P_{17}$	489.2774
$P_{18}$	489.3030
$P_{19}$	511.2787
$P_{20}$	511.2782
$P_{21}$	523.2861
$P_{22}$	523.3163
$P_{23}$	523.3153
$P_{24}$	523.2731
$P_{25}$	523.2684
$P_{26}$	523.2685
$P_{27}$	10.0000
$P_{28}$	10.0000
$P_{29}$	10.0000
$P_{30}$	95.6261
$P_{31}$	190.0000
$P_{32}$	189.9953
$P_{33}$	190.0000
$P_{34}$	200.0000
$P_{35}$	200.0000
$P_{36}$	200.0000
$P_{37}$	110.0000
$P_{38}$	110.0000
$P_{39}$	110.0000
$P_{40}$	511.3013
$\sum_{j=1}^{40} P_i$	10500.0000

**Fonte: Aatoria própria.**

(2007);

- DTSA (*Distributed Tabu Search Algorithm*) proposto por Khamsawang, Pothiya e Boonseng (2004);
- NPSO-LRS (*A New Particle Swarm Optimization*) proposto por Selvakumar e Thanushkodi (2007);
- CEP-PSO (*Particle Swarm Optimization*) proposto por Sinha e Purkayastha (2004);
- AIS-R (*Artificial Immune System with Real Representation*) proposto por Vanaja, Hemamalini e Simon (2008);
- CDEMD (*Cultural Differential Evolution with Measure population's Diversity*) proposto por Coelho, Souza e Mariani (2009).

Embora fosse melhor comparar o algoritmo com os outros propostos na literatura para todos os casos de estudo, isso foi impossível pelo fato que os demais trabalhos foram aplicados somente em um ou dois tipos de casos.

A Tabela 11 apresenta as comparações dos resultados obtidos pelos algoritmos propostos (IS, CIS e FCISr) e os melhores resultados obtidos nos trabalhos citados, para o problema de despacho econômico com 13 geradores e demanda de 1800 MW (COELHO; MARIANI, 2006):

Para esse caso os métodos propostos tiveram um desempenho semelhante aos melhores métodos comparados, obtendo melhor resultado para o menor custo com o FCISr e o CIS mostrou-se melhor que os outros métodos nos demais quesitos considerados.

Para o problema de despacho econômico com demanda de 2520MW, extraído de Khamsawang, Pothiya e Boonseng (2004), as metodologias propostas foram comparadas com dois trabalhos recentes. Essa comparação é apresentada na Tabela 12.

Para essa instância do problema os algoritmos propostos foram superados por ambos os algoritmos da literatura no valor de custo mínimo e pelo algoritmo SDE no valor de custo médio e de custo máximo.

**Tabela 11: Comparação entre os métodos propostos e outras abordagens da literatura para o caso com 13 Geradores e demanda de 1800 MW.**

<b>Método</b>	<b>Melhor Custo</b>	<b>Médio Custo</b>	<b>Pior Custo</b>
IS	17969,42	17972,33	17986,48
CIS	17961,43	<b>17970,16</b>	<b>17971,64</b>
FCISr	<b>17961,38</b>	17970,26	17977,73
DEC-SQP	17963,94	17973,13	17984,81
IGA	18063,58	18096,40	18293,47
MPSO	17973,34	-	-
AIS-R	17974,42	18006,35	18093,30
CDEMD	17961,94	17974,68	18061.4110

**Fonte: Autoria própria.**

**Tabela 12: Comparação entre os métodos propostos e outras abordagens da literatura para caso com 13 Geradores e demanda de 2520 MW.**

<b>Método</b>	<b>Melhor Custo</b>	<b>Médio Custo</b>	<b>Pior Custo</b>
IS	24170,44	24191,13	24289,00
CIS	24170,79	24174,90	24217,36
FCISr	24171,17	24177,14	24282,05
SDE	<b>24164,05</b>	<b>24168,28</b>	<b>24200,05</b>
DTSA	24169,05	-	-

**Fonte: Autoria própria.**

Para o problema de despacho econômico com 40 geradores e demanda de 10500 MW, reportado por Coelho e Mariani (2006), foram feitas comparações com quatro trabalhos recentes. A Tabela 13 apresenta as comparações dos resultados obtidos pelas metodologias propostas e os melhores resultados obtidos nos trabalhos reportados na literatura.

**Tabela 13: Comparação entre os métodos propostos e outras abordagens da literatura para o caso com 40 Geradores e demanda de 10500 MW.**

Método	Melhor Custo	Médio Custo	Pior Custo
IS	121496,69	121742,69	122157,34
CIS	121528,31	121744,08	122707,88
FCISr	121455,93	121630,36	121981,77
DEC-SQP	121741,97	122295,12	122839,29
NPSO-LRS	121664,43	122209,31	122981,59
CEP-PSO	123670,00	124145,60	124900,00
AIS-R	121432,18	<b>121484,23</b>	<b>121502,83</b>
CDEMD	<b>121423,40</b>	121526,73	121696,98

**Fonte: Autoria própria.**

Para essa instância do problema o melhor valor para custo mínimo foi encontrado pelo CDEMD. O melhor valor de custo médio foi reportado pelo algoritmo AIS-R, sendo que o algoritmo FCISr apresentou a terceira melhor média. No valor máximo do custo novamente o algoritmo AIS-R obteve o melhor valor seguido dos algoritmos CDEMD e FCISr.

Os resultados das Tabelas 11, 12 e 13 mostram que mesmo utilizando um conjunto de parâmetros *default* as abordagens propostas apresentaram desempenho comparável aos das outras abordagens propostas na literatura.



## 8 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou a proposta e implementação de sistemas híbridos baseados em Computação Natural capazes de solucionar, de forma eficiente, um complexo problema de otimização contínua. Mais especificamente, uniram-se Algoritmos Culturais, Sistemas Imunológicos Artificiais e Sistemas Fuzzy com o intuito de se produzir um sistema híbrido, o qual pudesse se beneficiar da cooperação destes paradigmas na solução de diferentes instâncias do problema de Despacho Econômico de energia elétrica com ponto de válvula.

Esta dissertação trouxe como contribuição principal a implementação de diferentes paradigmas híbridos baseados em Computação Natural cujo desempenho se mostrou satisfatório nos problemas considerados mesmo com um conjunto fixo de parâmetros.

Assim, foram geradas quatro abordagens diferentes: um Sistema imune ou Sistema Imunológico Artificial puro (IS), um Sistema imune cultural ou Sistema Imunológico Artificial com Algoritmo Cultural (CIS) e duas versões de um Sistema imune *fuzzy* cultural ou Sistema Imunológico Artificial com Algoritmo Cultural e função de Influência *Fuzzy* (FCIS), uma com função de reparação (FCISr) e outra com função de penalidade (FCISp).

Do ponto de vista de aplicação, os resultados mostraram que diferentes instâncias do problema de despacho econômico com ponto de válvula podem ser resolvidas de forma satisfatória, com um mesmo conjunto de parâmetros.

Quando comparadas com o estado-da-arte, as abordagens propostas se mostraram competitivas. Inclusive, no caso de 13 geradores e demanda de 1800MW, no quesito melhor custo, foi obtido um valor semelhante, pelas abordagens imune cultural e imune *fuzzy* cultural, ao melhor valor encontrado pelas abordagens de comparação consideradas.

A vantagem de se utilizar as abordagens apresentadas nesse trabalho é que bons resultados foram obtidos utilizando um mesmo conjunto de parâmetros em todos os casos do problema de despacho econômico de energia elétrica tratados nesse trabalho.

Também é possível observar algumas limitações ao utilizar esses métodos, visto que eles são complexos (grande número de parâmetros, por exemplo), dificultando ajustes finos na busca por melhores resultados.

## 8.1 TRABALHOS FUTUROS

Dentre os inúmeros pontos do trabalho que merecem uma continuidade de pesquisa destacam-se os seguintes itens:

- substituição do multiplicador adaptativo, o qual atua nas funções de influência de todos os conhecimentos (exceto o topográfico), por um multiplicador caótico;
- utilizar um fator variável em substituição à constante de penalidade (constante  $Q$  na equação 12);
- análise da distribuição dos conhecimentos ao longo do processo evolutivo para as melhores soluções geradas de forma a ajustar os parâmetros da base de regras utilizada pelo sistema de inferência *fuzzy*;
- avaliar de forma sistemática a influência dos diversos parâmetros do sistema imune *fuzzy* cultural e propor mecanismos de ajuste automático destes parâmetros;
- avaliar a possibilidade de utilização de um meta-espço de crenças para armazenar os conhecimentos de Espaços de Crenças distintos; ou seja, armazenar conhecimentos de populações diferentes, por exemplo, Algoritmos Genéticos, Sistemas Imunológicos Artificiais, Evolução Diferencial, etc.

## REFERÊNCIAS

ALMEIDA, C. P. **Aplicação de Sistemas Imunológicos Artificiais para a Predição da Estrutura de Proteínas**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Curitiba, PR, 2007.

ALMEIDA, C. P.; GONÇALVES, R. A.; DELGADO, M. R. d. B. d. S. Hybrid immune-based system for the protein folding problem. **Lecture Notes in Computer Science**, v. 4446, p. 13–24, 2007.

ALVES, R. et al. Discovering multi-label hierarchical classification rules for protein function prediction. In: PLASTINO, A. et al. (Ed.). **Proc. II Workshop em Algoritmos e Aplicações de Mineração de Dados (Workshop on Algorithms and Applications of Data Mining)**. Sociedade Brasileira de Computação, 2007. p. 87–90. ISBN 9788576691358. Disponível em: <<http://www.cs.kent.ac.uk/pubs/2007/2631>>.

ALVES, R. T.; DELGADO, M. R.; FREITAS, A. A. Multi-label hierarchical classification of protein functions with artificial immune systems. In: **BSB '08: Proceedings of the 3rd Brazilian symposium on Bioinformatics**. Santo André, Brazil: Springer-Verlag, 2008. p. 1–12. ISBN 978-3-540-85556-9.

ALVES, R. T. et al. An artificial immune system for fuzzy-rule induction in data mining. In: YAO, X. et al. (Ed.). **8th International Conference on Parallel Problem Solving from Nature**. Birmingham, UK: Springer-Verlag, 2004a. (Lecture Notes in Computer Science, v. 3242), p. 1011–1020.

ANCHOR, K. P. et al. Extending the computer defense immune system: Network intrusion detection with a multiobjective evolutionary programming approach. In: **ICARIS. 1st International Conference on Artificial Immune Systems**. University of Kent, Canterbury, 2002. p. 12–21.

ANILE, A. M. et al. Determination of protein structure and dynamics combining immune algorithms and pattern search methods. **Natural Computing: an international journal**, v. 6, n. 1, p. 55–72, 2007.

ANILE A. M. CUTELLO, V. et al. Lipschitzian pattern search and immunological algorithm with quasi-newton method for the protein folding problem: An innovative multistage approach. In: **NAI. Int. Workshop on Natural and Artificial Immune Systems**. Vietri sul Mare (SA), Italy: Springer, 2006. (Lecture Notes in Computer Science), p. 307–323.

ARANTES, M. B.; OLIVEIRA, G. T. S.; SARAMAGO, S. F. P. Evolução diferencial aplicada à solução de alguns problemas de engenharia de produção. **FAMAT em Revista**, n. 6, p. 48–61, 2006.

ARPAIA, P.; LUCARIELLO, G.; ZANESCO, A. Automatic fault isolation by cultural algorithms with differential evolution. **IEEE Transactions on Instrumentation and Measurement**, v. 56, n. 5, p. 1573–1582, 2007.

BALAMURUGAN, R.; SUBRAMANIAN, S. Self-adaptive differential evolution based power economic dispatch of generators with valve-point effects and multiple fuel options. **International Journal of Computer Science and Engineering**, v. 1, n. 1, p. 10–17, 2007.

BECERRA, R. L.; COELLO, C. A. Culturizing differential evolution for constrained optimization. In: **5nd Mexican International Conference in Computer Science (ENC'04)**. Colima, México: IEEE Computer Society, 2004. p. 304–311.

BECERRA, R. L.; COELLO, C. A. C. Optimization with constraints using a cultured differential evolution approach. In: **Proceedings of Genetic and Evolutionary Computation Conference**. Washington DC, USA: ACM, 2005. p. 27–34.

BECERRA, R. L.; COELLO, C. A. C. Cultured differential evolution for constrained optimization. **Computer Methods in Applied Mechanics and Engineering**, v. 208, n. 1, p. 273–283, 2006.

BERSINI, H. Artificial immune systems and their applications. In: DASGUPTA, D. Berlin, German: Springer-Verlag, 1999. cap. The Endogenous Double Plasticity of the Immune Network and the Inspiration to be Drawn for Engineering Aircrafts, p. 22–44.

BRADLEY, D. W.; TYRRELL, A. M. Immunotronics: Hardware fault tolerance inspired by the immune system. In: ICES. **International Conference on Evolvable Systems**. Edinburgh, Scotland, UK, 2000. p. 11–20. Disponível em: <[citeseer.ist.psu.edu/bradley00immunotronics.html](http://citeseer.ist.psu.edu/bradley00immunotronics.html)>.

BURNET, F. M. **The clonal selection theory of acquired immunity**. Nashville, Tennessee, USA: Vanderbilt University Press, 1959.

CANHAM, R.; JACKSON, A. H.; TYRRELL, A. Robot error detection using an artificial immune system. In: EH. **NASA/DoD Conference Evolvable Hardware**. Illinois, USA, 2003. p. 199–207.

CASTRO, L. N. de; TIMMIS, J. An artificial immune network for multimodal function optimization. **Evolutionary Computation, 2002. CEC '02**, Honolulu, HI, USA, v. 1, p. 699–704, 2002.

COELHO, L. d. S.; ALMEIRA, A. D. V. D.; MARIANI, V. C. Cultural differential evolution approach to optimize the economic dispatch of electrical energy using thermal generators. In: IEEE. **IEEE International Conference on Emerging Technologies and Factory Automation**. Hamburg, Germany, 2008. p. 1378–1383.

COELHO, L. d. S.; MARIANI, V. C. Combining of chaotic differential evolution and quadratic programming for economic dispatch optimization with valve-point effect. **IEEE Transactions on Power Systems**, v. 21, n. 2, p. 989–996, 2006.

COELHO, L. d. S.; SOUZA, R. C. T.; MARIANI, V. C. Improved differential evolution approach based on cultural algorithm and diversity measure applied to solve economic load dispatch problems. **Math. Comput. Simul.**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, v. 79, n. 10, p. 3136–3147, 2009. ISSN 0378-4754.

COELLO, C. A. C.; CORTÉS, N. C. Solving multiobjective optimization problems using an artificial immune system. **Genetic Programming and Evolvable Machines**, v. 6, n. 2, p. 163–190, Junho 2005.

CORTÉS, N. C.; TREJO-PÉREZ, D.; COELLO, C. A. C. Handling constraints in global optimization using an artificial immune system. In: ICARIS. **4th International Conference on Artificial Immune Systems**. Banff AB, Canadá, 2005. (Lecture Notes in Computer Science, v. 3627), p. 234–247.

COSTA, A. M. et al. Makespan minimization on parallel processors: An immune-based approach. In: TIMMIS, J.; BENTLEY, P.; HART, E. (Ed.). **Special Sessions on Artificial Immune Systems in the Congress on Evolutionary Computation**. Honolulu, Hawaii, 2002. (Lecture Notes in Computer Science, v. 2787), p. 11–21.

CUTELLO, V. et al. Immune algorithms with aging operators for the string folding problem and the protein folding problem. In: EVOCOP. **5th European Conference on Computation in Combinatorial Optimization**. Lausanne, Switzerland, 2005. v. 3448, p. 80–90.

CUTELLO, V.; NARZISI, G.; NICOSIA, G. A multi-objective evolutionary approach to the protein structure prediction problem. **Journal of the Royal Society Interface**, v. 3, n. 6, p. 139–151, 2006.

CUTELLO, V. et al. Real coded selection algorithm for global numerical optimization using a new inversely proportional hypermutation operator. In: ACM. **Symposium on Applied Computing**. Dijon, France, 2006. v. 2, p. 950–954.

CUTELLO, V. et al. On the convergence of immune algorithms. In: IEEE. **The First IEEE Symposium on Foundations of Computational Intelligence, FOCI**. Honolulu, Hawaii, USA, 2007. p. 409–415.

CUTELLO, V.; NICOSIA, G.; PAVONE, M. A hybrid immune algorithm with information gain for the graph coloring problem. In: GECCO. **Genetic and Evolutionary Computation Conference**. Illinois, USA, 2003. (Lecture Notes in Computer Science, v. 2723), p. 171–182.

CUTELLO, V.; NICOSIA, G.; PAVONE, M. Exploring the capability of immune algorithms: A characterization of hypermutation operators. In: ICARIS. **Third International Conference on Artificial Immune Systems**. Catania, Italy, 2004. p. 263–276.

CUTELLO, V. et al. An immune algorithm for protein structure prediction on lattice models. **IEEE Transactions on Evolutionary Computation**, v. 11, n. 1, p. 101–117, 2006.

DASGUPTA, D. **Artificial Immune System and Their Applications**. Berlin, Deutschland: Springer-Verlag, 1999.

De Castro, L. N. **Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais**. Tese (Doutorado) — Universidade Estadual de Campinas - Faculdade de Engenharia Elétrica e de Computação, 2001.

De Castro, L. N. **Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications**. Boca Raton, FL, USA: Chapman & Hall/CRC, 2006.

De Castro, L. N.; ZUBEN, F. J. V. Learning and optimization using the clonal selection principle. **IEEE Transactions on Evolutionary Computation, Special Issue on Artificial Immune Systems**, v. 6, n. 3, p. 239–251, 2001.

De Paula, F. S.; De Castro, L. N.; GEUS, P. L. de. An intrusion detection system using ideas from the immune system. In: CEC. **International Conference on Evolutionary Computation**. San Diego, CA, USA, 2004. p. 1059–1066.

DELGADO, M. R. d. B. d. S. **Projeto Automático de Sistemas Nebulosos: Uma Abordagem Co-Evolutiva**. Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, Campinas, SP, 2002.

DING, Y.; REN, L. Fuzzy self-tuning immune feedback controller for tissue hyperthermia. In: IEEE. **IEEE International Conference on Fuzzy Systems**. San Antonio, Texas, USA, 2000. v. 1, p. 534–538.

DONG, W. et al. The optimization of mixture ratio of model sand based on simplex particle swarm optimization algorithm. In: CCDC. **Chinese Control and Decision Conference -CCDC'2008**. Yantai, Shandong, 2008. p. 3868–3872.

DORIGO, M.; MANIEZZO, V.; COLORNI, A. **The Ant System: An Autocatalytic Optimizing Process**. Milano, Italy, 1991.

DORIGO, M.; STUTZLE, T. **The Ant Colony Optimization Metaheuristic: Algorithms, Applications and Advances**. Norwell, MA, USA: Kluwer Academic Publishers, 2003. 251–285 p.

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. **Proceedings of the Sixth International Symposium on Micro Machine and Human Science. MHS '95**, Nagoya, Japan, p. 39–43, 1995.

EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the Bootstrap**. Boca Raton, FL, USA: Chapman & Hall/CRC, 1993.

FRANÇA, F. O.; Von Zuben, F. J.; De Castro, L. N. An artificial immune network for multi-modal function optimization on dynamic environments. In: **GECCO. Genetic and Evolutionary Computation**. Washington, DC, USA, 2005. p. 289–296.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Boston, MA: Addison Wesley Longman, 1989.

GOMES, L. C. T. **Inteligência Computacional na Síntese de Meta-Heurísticas para Otimização Combinatória e Multimodal**. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, SP, 2006.

GONÇALVES, R. A. et al. A cultural immune system for economic load dispatch with non-smooth cost functions. In: **ICARIS. 6th International Conference on Artificial Immune Systems**. Santos, Brazil, 2007. (Lecture Notes in Computer Science, v. 4628), p. 382–394.

GONZÁLEZ, F. A.; DASGUPTA, D. Anomaly detection using real-valued negative selection. **Genetic Programming and Evolvable Machines**, v. 4, n. 4, p. 383–403, 2003.

GREENSMITH, J.; AICKELIN, U.; TWYXCROSS, J. Detecting danger: Applying a novel immunological concept to intrusion detection systems. In: **6th International Conference in Adaptive Computing in Design and Manufacture**. Clifton, Bristol, UK: [s.n.], 2004.

GUDWIN, R. R.; ZUBEN, F. J. V. **Programação Genética**. 1998. [Ftp://ftp.dca.fee.unicamp.br/pub/docs/ia707/aula10.pdf](http://ftp.dca.fee.unicamp.br/pub/docs/ia707/aula10.pdf).

HAAG, C. R. et al. An artificial immune system-inspired multiobjective evolutionary algorithm with application to the detection of distributed computes network intrusion. In: **ICARIS. 6th International Conference on Artificial Immune Systems**. Santos, Brazil, 2007. (Lecture Notes in Computer Science, v. 4628), p. 420–435.

HOLLAND, J. H. Outline for a logical theory of adaptive systems. **J. ACM**, ACM, New York, NY, USA, v. 9, n. 3, p. 297–314, 1962. ISSN 0004-5411.

HONÓRIO, L. M.; SILVA, A. M. L.; BARBOSA, D. A. A gradient-based artificial immune system applied to optimal power flow problems. In: ICARIS. **6th International Conference on Artificial Immune Systems**. Santos, Brazil, 2007. (Lecture Notes in Computer Science, v. 4628), p. 1–12.

HOU, Y. et al. Economic dispatch of power systems based on the modified particle swarm optimization algorithm. **IEEE/PES Transmission and Distribution Conference and Exhibition**, Los Alamitos, CA, USA, p. 1–6, 2005.

IACOBAN, R.; REYNOLDS, R. G.; BREWSTER, J. Cultural swarm: Modeling the impact of culture on social interaction and problem solving. In: **IEEE Proceedings of Congress on Evolutionary Computation**. Detroit, MI, USA: [s.n.], 2003. p. 205–211.

ISHIGURO, A. et al. Moderationism in the immune system: Gait acquisition of a legged robot using the metadynamics function. In: SMC. **IEEE System, Man, and Cybernetics Conference**. San Diego, USA, 1998. p. 3827–3832.

JANG, J. S.; SUN, C. T.; MIZUTANI, E. **Neuro-fuzzy and Soft Computing: a Computational approach to Learning and Machine Intelligence**. USA: Prentice Hall, 1997.

JERNE, N. K. Towards a network theory of the immune system. **Annales d'immunologie**, Ann Immunol (Inst Pasteur), v. 125C, n. 1-2, p. 373–389, 1974.

KHAMSAWANG, S.; POTHIIYA, S.; BOONSENG, C. Distributed tabu search algorithm for solving the economic dispatch problem. In: **TENCON**. Chiang Mai, Thailand: [s.n.], 2004. p. 484–487.

KIM, D. H. Tuning of a pid controller using an artificial immune network model and local fuzzy set. In: IFA/NAFIPS. **International Conference IFSA World Congress and 20th NAFIPS**. Vancouver, Canada, 2001. v. 5, p. 2698–2703.

KOZA, J. R. **Genetic programming: a paradigm for genetically breeding populations of computer programs to solve problems**. Stanford, CA, USA, 1990.

LAGARIAS, J. C. et al. Convergence properties of the nelder-mead simplex method in low dimensions. **Society for Industrial and Applied Mathematics**, v. 9, n. 1, p. 112–147, 1998.

LAU, H. Y. K.; KO, A. An immuno robotic system for humanitarian search and rescue. In: ICARIS. **6th International Conference on Artificial Immune Systems**. Santos, Brazil, 2007. (Lecture Notes in Computer Science, v. 4628), p. 191–203.

LAW, H. Y. K.; WONG, V. W. K. Immunologic control framework for automated material handling. In: TIMMIS, J.; BENTLEY, P.; HART, E. (Ed.). **Second International Conference on Artificial Immune Systems**. Edinburgh, UK, 2004. (Lecture Notes in Computer Science, v. 2787), p. 57–68.



- LEE, D. et al. Immune-based framework for exploratory bio-information retrieval from the semantic web. In: TIMMIS, J.; BENTLEY, P.; HART, E. (Ed.). **Second International Conference on Artificial Immune Systems**. Edinburgh, UK, 2003. (Lecture Notes in Computer Science 2787), p. 128–135.
- LEE, S. et al. A new immunotronic approach to hardware fault detection using symbiotic evolution. In: IWINAC. **1st International Work-Conference on the Interplay Between Natural and Artificial Computation**. Canary Islands, Spain, 2005. (Lecture Notes in Computer Science, v. 3562), p. 133–142.
- LIN, C.-J.; CHEN, C.-H.; LIN, C.-T. A hybrid of cooperative particle swarm optimization and cultural algorithm for neural fuzzy networks and its prediction applications. **IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews**, v. 39, n. 1, p. 55–68, 2009.
- LING, S. et al. Improved genetic algorithm for economic load dispatch with valve-point loadings. In: IEEE. **29th Annual Conference of the IEEE Industrial Electronics Society (IECON'03)**. Kowloon, China, 2003. p. 442–447.
- MACKERELL, A. D. J. et al. The encyclopedia of computational chemistry. In: \_\_\_\_\_. [S.l.]: John Wiley & Sons, 1998. v. 1, cap. CHARMM: The Energy Function and Its Parameterization with an Overview of the Program, p. 271–277.
- MAZHAR, N.; FAROOQ, M. Beeais: Artificial immune system security for nature inspired, manet routing protocol, beeadhoc. In: ICARIS. **6th International Conference on Artificial Immune Systems**. Santos, Brazil, 2007. (Lecture Notes in Computer Science, v. 4628), p. 370–381.
- MICHALEWICZ, Z.; SCHOENAUER, M. Evolutionary algorithms for constrained parameter optimization problems. **Evol. Comput.**, v. 4, n. 1, p. 1–32, 1996.
- NOMAN, N.; IBA, H. Differential evolution for economic load dispatch problems. **Electric Power Systems Research**, Elsevier Science Publishers B. V., v. 78, n. 8, p. 1322–1331, 2008.
- OLIVEIRA, G. T. d. S. **Estudo e Aplicações da Evolução Diferencial**. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, MG, 2006.
- PEDRYCZ, W.; GOMIDE, F. **An Intruction to Fuzzy Sets: Analysis and Design**. London, UK: Cambridge: MIT Press, 1998.
- PEDRYCZ, W.; GOMIDE, F. **Fuzzy Systems Engineering - Toward Human-Centric Computing**. [S.l.]: John Wiley & Sons, 2007.

REYES-SIERRA, M.; COELLO, C. A. C. Multi-objective particle swarm optimizers: A survey of the state-of-the-art. **International Journal of Computational Intelligence Research**, v. 2, n. 3, p. 287–308, 2006.

REYNOLDS, R. G. An introduction to cultural algorithm. In: **Proceedings of the 3rd Annual Conference on Evolutionary Programming**. San Diego, USA: World Scientific Publishers, 1994. p. 131–139.

REYNOLDS, R. G. **Tutorial on Cultural Algorithms**. 2003. IEEE Swarm Intelligence Symposium.

REYNOLDS, R. G.; ALI, M. Z. A social fabric approach as an approach to knowledge integration in cultural algorithms. In: IEEE. **IEEE Congress on Evolutionary Computation**. Hong Kong, 2008. p. 4200–4207.

REYNOLDS, R. G.; CHUNG, C. Fuzzy approaches to acquiring experimental knowledge in cultural algorithms. In: **ICTAI '97: Proceedings of the 9th International Conference on Tools with Artificial Intelligence**. Newport Beach, CA, USA: IEEE Computer Society, 1997. p. 260–267.

REYNOLDS, R. G.; PENG, B. Cultural algorithms: computational modeling of how cultures learn to solve problems: an engineering example. **Cybernetics and Systems**, v. 36, n. 8, p. 753–771, 2005.

REYNOLDS, R. G.; PENG, B. Knowledge integration on-the-fly in swarm intelligent systems. **IEEE International Conference on Tools with Artificial Intelligence**, IEEE Computer Society, Los Alamitos, CA, USA, p. 197–210, 2006.

REYNOLDS, R. G.; ZHU, S. Knowledge-based function optimization using fuzzy cultural algorithms with evolutionary programming. **IEEE Transactions on Systems, Man, and Cybernetics - Part B: Cybernetics**, v. 31, n. 1, p. 1–18, 2001.

RODRIGUES, N. M. **Um Algoritmo Cultural para Problemas de Despacho Econômico de Energia Elétrica**. Dissertação (Mestrado) — Universidade Estadual de Maringá, Maringá, PR, 2007.

SALEEM, S. M. **Knowledge-based Solution to Dynamic Optimization Problems using Cultural Algorithms**. Tese (Doutorado) — Wayne State University, Detroit, MI, USA, 2001.

SCHERER, A. Combining neural networks with other prediction techniques. In: **Proceedings of the 29th Annual Hawaii International Conference on System Sciences**. Maui, Hawaii: IEEE, 1996. p. 437–446.

- SELVAKUMAR, A. I.; THANUSHKODI. A new particle swarm optimization solution to non-convex economic dispatch problems. **IEEE Transactions on Power Systems**, v. 22, n. 1, p. 42–51, 2007.
- SHAFIQ, M. Z.; FAROOQ, M. Defence against 802.11 dos attacks using artificial immune system. In: ICARIS. **6th International Conference on Artificial Immune Systems**. Santos, Brazil, 2007. (Lecture Notes in Computer Science, v. 4628), p. 95–106.
- SINHA, N.; CHAKRABARTI, R.; CHATTOPADHYAY, P. K. Improved fast evolutionary program for economic load dispatch with non-smooth cost curves. **IE Journal**, v. 85, n. 2, p. 110–114, 2004.
- SINHA, N.; PURKAYASTHA, B. Pso embedded evolutionary programming technique for non-convex economic load dispatch. **IEEE/PES Power Systems Conference and Exposition 1**, v. 1, p. 66–71, 2004.
- SPENDLEY, W.; HEXT, G.; HIMSWORTH, F. Sequential application of simplex designs in optimisation and evolutionary operation. **Technometrics**, v. 4, n. 4, p. 441–461, 1962.
- STORN, R.; PRICE, K. **Differential Evolution - A simple and efficient adaptive scheme for global optimization over continuous spaces**. [S.l.], 1995. Disponível em: <<http://www.icsi.berkeley.edu/storn/TR-95-012.pdf>>.
- TIMMIS, J. Artificial immune systems - today and tomorrow. **Natural Computing: an international journal**, v. 6, n. 1, p. 1–18, 2007.
- VANAJA, B.; HEMAMALINI, S.; SIMON, S. P. Artificial immune based economic load dispatch with valve-point effect. In: IEEE. **TENCON**. Hyderabad, Andhra Pradesh, India, 2008. p. 1–5.
- VARGAS, P. A. et al. Implementation of an immuno-genetic network on a real khepera ii robot. In: CEC. **Congress on Evolutionary Computation**. Newport Beach, CA, USA, 2003. v. 1, p. 420–426.
- WALKER, J. A.; MILLER, J. F. The automatic acquisition, evolution and reuse of modules in cartesian genetic programming. **IEEE Transaction on Evolutionary Computation**, v. 12, n. 4, p. 397–417, 2008.
- WALKER, J. H.; GARRETT, S. M. Dynamic function optimisation: Comparing the performance of clonal selection and evolution strategies. In: TIMMIS, J.; BENTLEY, P.; HART, E. (Ed.). **Proc. Of the Second International Conference on Artificial Immune Systems**. Edinburgh, UK, 2003. (Lecture Notes in Computer Science, v. 2787), p. 273–284.
- WANG, F.; LIU, D. **Advances in Computational Intelligence: Theory and Applications**. Hackensack, NJ, USA: World Scientific Publishing, 2006.

WANG, L.; HIRSBRUNNER, B. Immune mechanism based computer security design. In: **ICMLC. International Conference on Machine Learning and Cybernetics**. Beijing, China, 2002. v. 4, p. 1887–1893.

WATKINS, A.; TIMMIS, T.; BOGGESS, L. Artificial immune recognition system (airs): An immune inspired supervised machine learning algorithm. **Genetic Programming and Evolvable Machines**, v. 5, n. 1, p. 291–317, 2004.

YUAN, X. et al. A chaotic hybrid cultural algorithm for constrained optimization. In: **WGEC '08: Proceedings of the 2008 Second International Conference on Genetic and Evolutionary Computing**. Hubei, China: [s.n.], 2008. p. 307–310.

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 8, p. 338–352, 1965.

ZHANG, X. et al. Research on invasive weed optimization based on the cultural framework. In: **3rd International Conference on Bio-Inspired Computing: Theories and Applications**. Adelaide, SA, Australia: [s.n.], 2008. p. 129–134.

## APÊNDICE A – QUASI-SIMPLEX


O método base do *Simplex* foi apresentado por Spendley, Hext e Himsworth (1962) por meio de um método de otimização contínuo da classe de métodos diretos (não fazem uso de derivadas) para calcular o valor mínimo de uma função. Esse método possuía as operações de reflexão e compressão. Com o decorrer do tempo um método *simplex* não linear, baseado no método base, foi desenvolvido por Nelder e Mead (DONG et al., 2008), incluindo as operações de expansão e contração. Por ser um método direto ele é particularmente útil na otimização de funções não suaves. Na prática a operação de compressão quase não ocorre e não será discutida, visto que não é uma operação relevante para o método quasi-simplex.

Desde sua publicação em 1965, o método *simplex* de Nelder-Mead tem sido um dos métodos mais amplamente utilizados em otimização não-linear por causa da sua simplicidade. O método de Nelder-Mead às vezes é confundido com o método que, provavelmente, é o método *simplex* mais conhecido desenvolvido por Dantzig para programação linear. A principal diferença entre ambos é que o método de Nelder-Mead é para otimização não-linear.

Um método simplex de Nelder-Mead tradicional inicializa com um conjunto de  $n+1$  de pontos  $\{X_0, X_1, \dots, X_n, X_{n+1}\}$ , onde  $n$  é a dimensão da função a ser otimizada, que são considerados como sendo vértices de um simplex  $S$  e o conjunto correspondente de valores nos vértices para a função a ser otimizada ( $f_j = f(X_j)$ , para  $j = 0 \dots n + 1$ ). Os pontos iniciais de um simplex não podem estar contidos num mesmo hiperplano (senão o simplex é considerado degenerado). Os vértices são ordenados de acordo com o valor da função no vértice (ordem crescente).

Então é calculado o centróide do simplex através da fórmula:  $X_c = 1/n \sum_{j=0}^n X_j$ , ou seja, o pior vértice não entra no cálculo do centróide na tentativa de direcionar a busca na direção dos melhores vértices.

O método então executa um conjunto de transformações no conjunto atual de vértices do simplex  $S$ , na tentativa de decrementar os valores da função nos vértices do simplex (problema de minimização). Todas as transformações, de alguma forma, envolvem o pior vértice no seu cálculo. A cada passo, a transformação é determinada pelo cálculo de um ou mais pontos de testes juntamente com os valores da função nesses pontos e pela comparação desses valores de função com aqueles de alguns vértices do simplex. O processo de transformações é repetido até que um critério de parada seja atingido. Geralmente, esse critério é a convergência do método. A Figura 27 apresenta exemplos de transformações utilizadas no método simplex de Nelder-Mead.



**Figura 27:** Exemplo de reflexão, expansão e compressão, respectivamente, do *simplex* Nelder-Mead; o *simplex* original é apresentado nas linhas pontilhadas

Fonte: Lagarias et al. (1998).

As diferenças entre o método *simplex* e o método *quasi-simplex* desenvolvido aqui são:

- No *simplex* o conjunto inicial de  $n+1$  pontos deve formar um *simplex* não degenerado

enquanto no caso do quasi-simplex nenhuma restrição é imposta (ou seja, podem estar no mesmo plano);

- As transformações no simplex obedecem uma ordem enquanto no quasi-simplex todas as transformações são realizadas e as que obtiveram os melhores resultados são aceitas (transformações gulosas);
- O simplex realiza as transformações sobre o pior vértice. Já o quasi-simplex realiza as transformações sobre o pior e o melhor vértice;
- O critério de parada do simplex, geralmente, é baseado no conceito de convergência enquanto o critério de parada do quasi-simplex é baseado num número máximo de iterações<sup>1</sup>.

As seguintes transformações foram implementadas no *quasi-simplex*: reflexão, expansão (duas fórmulas) e compressão. Como dito anterior, as transformações do quasi-simplex são aplicadas tanto no pior vértice quanto no melhor vértice. Essas transformações são detalhadas a seguir:

- **Reflexão:** para a pior solução é feita através da fórmula  $X_r = X_p + (X_p - X_c)$ , onde  $X_r$  é a nova solução gerada,  $X_p$  é a pior solução (pior vértice do simplex) e  $X_c$  é o centróide do simplex. Já para a melhor solução a reflexão é feita por meio da fórmula  $X_r = X_m + (X_c - X_m)$ , onde  $X_r$  é a nova solução gerada,  $X_m$  é a melhor solução (melhor vértice) e  $X_c$  é o centróide;
- **Expansão:** além de ser realizada na melhor e pior solução, existem dois tipos de expansão: para a pior solução são utilizadas as fórmulas  $X_r = X_p + (1 + \alpha)(X_p - X_c)$  e  $X_r = X_p + \alpha(X_p - X_c)$ , onde  $X_r$ ,  $X_p$  e  $X_c$  são definidos como anteriormente e  $\alpha$  é uma variável uniforme no intervalo 0 a 1. Para a melhor solução a fórmula utilizada é  $X_r = X_m + (1 + \alpha)(X_c - X_m)$  e  $X_r = X_m + \alpha(X_c - X_m)$ ; onde todas as variáveis são como definidas anteriormente;

---

<sup>1</sup>Visto que não espera-se que o método convirja e que o quasi-simplex está sendo utilizado como uma busca local fraca.

- **Compressão:** para a pior solução a compressão é feita por meio da fórmula  $X_r = X_p - \alpha(X_p - X_c)$ , onde todas as variáveis são como definidas anteriormente. Para a melhor solução a compressão é feita através da fórmula  $X_r = X_m - \alpha(X_c - X_m)$ , onde as variáveis são como definidas anteriormente.

Após aplicação da reflexão, expansão e compressão, os sete piores indivíduos da população são substituídos por sete novos indivíduos gerados por meio do método *quasi-simplex*.



## APÊNDICE B – SISTEMA DE INFERÊNCIA *FUZZY* DESENVOLVIDO

O Sistema de Inferência *Fuzzy* (SIF) desenvolvido nesse trabalho foi gerado através de uma *engine*<sup>1</sup> implementada em Java. A *engine* é fornecida como um pacote Java, a qual pode ser facilmente utilizada em sistemas implementados em Java.

Foram desenvolvidos SIF para cada conhecimento (Situacional, Normativo, Topográfico e Histórico), visto que cada conhecimento atua melhor de forma e em momentos distintos.

Os SIF possuem as seguintes características:

- Quatro variáveis linguísticas: três variáveis de entrada (idade da população, diversidade da população e qualidade do indivíduo) e uma variável de saída (percentual possível de aplicação do conhecimento associado ao SIF). Todas as variáveis linguísticas têm como universo de discurso valores entre 0 e 1;
- Para a variável idade os termos associados são inicial, intermediária e final, para diversidade são pouca, média e muita, e para qualidade são baixa, média e alta; a variável de saída quantidade possui os termos pouco, médio e muito associados a ela;
- Base de regras: cada SIF possui sua base de regras, contendo 27 regras por SIF (idade x diversidade x qualidade), totalizando 108 regras.

As variáveis linguísticas (entrada e saída) são do tipo trapezoidal com parâmetros  $(a, m, n, b)$  onde  $a$  e  $b$  identificam os valores onde a função de pertinência atinge o valor 0 (zero) e  $m$  e  $n$  onde ela atinge o valor 1 (um) identifica. Nos experimentos realizados as funções trapezoidais utilizam os seguintes valores (definidos pelo especialista):

---

<sup>1</sup><http://www.intelligent-systems.info/FuzzyEngine.htm>

**1.Idade:**

- Inicial: 0, 0, 0.15, 0.3;
- Intermediaria: 0.15, 0.3, 0.6, 0.75;
- Final: 0.45, 0.75, 1, 1);

**2.Diversidade:**

- Pouca: 0, 0, 0.2, 0.45;
- Media: 0.2, 0.45, 0.55, 0.75;
- Muita: 0.55, 0.75, 1, 1;

**3.Qualidade:**

- Baixa: 0, 0, 0.2, 0.45;
- Media: 0.2, 0.45, 0.55, 0.75;
- Alta: 0.55, 0.75, 1, 1;

**4.Aplicar conhecimento:**

- Pouco: 0, 0, 0.12, 0.27;
- Medio: 0.14, 0.46, 0.54, 0.86;
- Muito: 0.64, 0.96, 1, 1;

As Tabelas 14, 15, 16 e 17 apresentam as regras utilizadas para os conhecimentos Situacional, Normativo, Histórico e Topográfico, respectivamente.

As regras foram desenvolvidas com base no seguinte raciocínio: o processo evolutivo foi dividido em três partes, que são início, meio e fim. No início da evolução foi realizado um processo para aumentar a diversidade dos indivíduos, por meio dos conhecimentos Topográfico e Histórico. O histórico é usado bastante no início para armazenar os eventos importantes. Durante o período intermediário do processo, a idéia é que ocorra um certo nivelamento entre os conhecimentos, para não aumentar demais a diversidade. No final do processo, o objetivo é

encontrar os melhores indivíduos, sendo assim a busca é intensificada com os conhecimentos Situacional e Normativo.

**Tabela 14: Base de Regras para o Conhecimento Situacional.**

Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Muito

Como visto no Capítulo 6, o mecanismo de raciocínio utilizado é do tipo Mamdani, com as seguintes características:

- **Agregação dos Antecedentes:** produto algébrico;
- **Semântica da Regra:** mínimo (Regra de Mamdani);

**Tabela 15: Base de Regras para o Conhecimento Normativo.**

Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Muito

**Tabela 16: Base de Regras para o Conhecimento Histórico.**

Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Pouco

**Tabela 17: Base de Regras para o Conhecimento Topográfico.**

Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Inicial e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Intermediária e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Pouca e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Baixa então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Média então <b>A</b> é Médio
Se <b>I</b> é Final e <b>D</b> é Média e <b>Q</b> é Alta então <b>A</b> é Muito
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Baixa então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Média então <b>A</b> é Pouco
Se <b>I</b> é Final e <b>D</b> é Muita e <b>Q</b> é Alta então <b>A</b> é Pouco

- **Agregação das Regras:** máximo;
- **Método de Defuzzificação:** centróide.