

UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

**SISTEMAS COMPUTACIONAIS BIO-INSPIRADOS:  
SÍNTESE E APLICAÇÃO EM INTELIGÊNCIA  
COMPUTACIONAL E HOMEOSTASE ARTIFICIAL**

**Patrícia Amâncio Vargas**

Orientador: Prof. Dr. Fernando José Von Zuben

Co-orientador: Prof. Dr. Leandro Nunes de Castro Silva

Tese apresentada à Pós-Graduação da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos pré-requisitos exigidos para a obtenção do título de Doutor em Engenharia Elétrica.

Área de Concentração: **Engenharia de Computação**

Campinas – São Paulo – Brasil

Abril de 2005

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

V426s Vargas, Patrícia Amâncio  
Sistemas computacionais bio-inspirados: síntese e aplicação em inteligência computacional e homeostase artificial / Patrícia Amâncio Vargas. --Campinas, SP: [s.n.], 2005.

Orientadores: Fernando José Von Zuben, Leandro Nunes de Castro Silva.  
Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Inteligência artificial. 2. Redes neurais (Computação). 3. Sistema imune. 4. Sistema endócrino. 5. Homeostase. 6. Algoritmos genéticos. 7. Robôs móveis. I. Von Zuben, Fernando José. II. Silva, Leandro Nunes de Castro. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Título em Inglês: Bioinspired Computing Systems: Synthesis and Application in Computational Intelligence and Artificial Homeostasis.

Palavras-chave em Inglês: Complex systems, Bioinspired computing systems, Artificial homeostasis, Computational intelligence e Robot autonomous navigation

Área de concentração: Engenharia de Computação

Titulação: Doutora em Engenharia Elétrica

Banca examinadora: Christiano Lyra Filho, Márcio Luiz de Andrade Netto, Marconi Kolm Madrid, José Roberto Campanha e Gina Maira Barbosa de Oliveira

Data da defesa: 15/04/2005

## **BANCA EXAMINADORA**

---

Orientador: Prof. Dr. Fernando José Von Zuben  
(DCA/FEEC/Unicamp)

---

Co-orientador: Prof. Dr. Leandro Nunes de Castro Silva  
(Unisantos – Santos – SP)

---

1º Membro Interno: Prof. Dr. Christiano Lyra Filho  
(DENSIS/FEEC/Unicamp)

---

2º Membro Interno: Prof. Dr. Márcio Luiz de Andrade Netto  
(DCA/FEEC/Unicamp)

---

3º Membro Interno: Prof. Dr. Marconi Kolm Madrid  
(DSCE/FEEC/Unicamp)

---

1º Membro Externo: Profa. Dra. Gina Maira Barbosa de Oliveira  
(FACOM/UFU – Uberlândia – MG)

---

2º Membro Externo: Prof. Dr. José Roberto Campanha  
(IGCE/UNESP – Rio Claro – SP)

## Resumo

Este trabalho propõe uma classificação circunstancial para sistemas complexos, incluindo uma estrutura unificada de descrição a ser empregada na análise e síntese de sistemas computacionais bio-inspirados. Como um ramo dos sistemas complexos organizados, os sistemas computacionais bio-inspirados admitem uma sub-divisão em sistemas de inteligência computacional e sistemas homeostáticos artificiais. Com base neste formalismo, duas abordagens híbridas são concebidas e aplicadas em problemas de navegação autônoma de robôs. A primeira abordagem envolve sistemas classificadores com aprendizado e sistemas imunológicos artificiais, visando explorar conjuntamente conceitos intrínsecos a sistemas complexos, como auto-organização, evolução e cognição dinâmica. Fundamentada nas interações neuro-imuno-endócrinas do corpo humano, a segunda abordagem propõe um novo modelo de sistema homeostático artificial, explorando mudanças de contexto e efeitos do meio sobre o comportamento autônomo de um robô móvel. Embora preliminares, os resultados obtidos envolvem simulação computacional em ambientes virtuais e alguns experimentos com robôs reais, permitindo extrair conclusões relevantes acerca do potencial das abordagens propostas e abrindo perspectivas para a síntese de sistemas complexos adaptativos de interesse prático.

## Abstract

This work proposes a circumstantial classification for complex systems, including a unified description structure to be employed in the analysis and synthesis of biologically inspired computing metaphors. Considered as a branch of organized complex systems, these bio-inspired computing frameworks may be subdivided into computation intelligence systems and artificial homeostatic systems. Developed under this formalism, two novel hybrid systems are conceived and applied to robot autonomous navigation problems. The first approach involves learning classifier systems and artificial immune systems, in an attempt to investigate intrinsic concepts of complex systems as self-organization, evolution, and dynamic cognition. Drawn on the principles of the human nervous, immune and endocrine systems, the second approach envisages a new model of an artificial homeostatic system to explore context changes and environmental effects on the behaviour of an autonomous robotic agent. Though preliminary, the obtained results encompass computer simulation on virtual environments in addition to a number of real robot's experiments. Relevant conclusions can be invoked, mainly related to the potentiality of the proposed frameworks, thus opening attractive prospects for the synthesis of complex adaptive systems of practical interest.

Este trabalho é dedicado à minha mãe  
**Diná**  
e à memória de meu irmão  
**Eduardo**

## Agradecimentos

O desenvolver deste trabalho contou com a participação direta e indireta de várias pessoas. Dentre elas, gostaria de externar primeiramente minha gratidão ao amigo e orientador Professor Fernando José Von Zuben. Muitos foram os momentos de *dores*, mas também inúmeros foram os momentos de *prazeres*. Devo a esta pessoa maravilhosa e dotada de um caráter íntegro, grande parte de meu crescimento como pessoa e como profissional. O meu muito obrigado Fernando! Desejo que você continue sua caminhada de sucesso com muita garra. Sucesso este, mais do que merecido.

Agradeço igualmente ao meu co-orientador Professor Leandro Nunes de Castro Silva pelas valiosas contribuições no decorrer da tese e pela amizade. Que Deus ilumine seu caminho, Leandro!

Dou continuidade aos agradecimentos exaltando outra pessoa a quem devo também minha gratidão, o Professor Christiano Lyra Filho. Através de sua orientação durante o mestrado, deu-se início o meu contato com a carreira docente. Com o mestre Christiano eu aprendi a admirar e a me apaixonar pela profissão. Hoje, com orgulho posso apontá-lo como um dos motivos por eu ter perseverado e alcançado o meu tão sonhado título de doutora! Sou muito grata Professor Christiano pela inspiração e espero que o senhor continue sendo esta pessoa iluminada que tanto admiro.

Ofereço agradecimentos distintos aos Professores Jonathan Timmis (University of Kent) e Mark Neal (University of Wales) pela oportunidade de desenvolver parte de meu trabalho em conjunto com seus grupos de pesquisa e pelo acolhimento durante a minha visita.

Nesses quatro anos de tese tive a oportunidade de conhecer e de reencontrar vários colegas, tanto da pós quanto da graduação, incluindo o pessoal da BAE, CPG e do DCA. Todos, de uma forma ou de outra, se tornaram parte deste trabalho. Gostaria de enaltecer em especial os meus amigos(as) do LBiC (Laboratório de Bioinformática e de Computação Bio-Inspirada), em particular a Renan pelo apoio durante as simulações e Wilfredo pela colaboração na edição das

figuras. Todos foram companheiros e solidários em todos os momentos de minha trajetória. Boa sorte, meninos e meninas!

Não poderia deixar de mencionar os amigos e amigas fora do círculo acadêmico. Sei que exigi muita compreensão de todos vocês durante todo o processo e peço perdão pelos justificáveis momentos de ausência. Um obrigado exclusivo a Nayara e Cristina, minhas psicólogas favoritas! Nayara, você em particular me mostrou o que realmente significa uma amizade. Siga em frente e nunca se esqueça que você é muito especial. Seja muito feliz! Cristina, grande companheira durante tantos anos. Aprendi muito com você e desejo que essa nossa amizade perdure para sempre!

Agradeço a toda minha família, que esteve sempre presente, apesar da distância. Em especial à tia Raulina, minha amiga e confidente. Obrigada tia pela sua dedicação! Amo você!

Às vezes me pergunto: O que seria de mim sem minha preciosa mãe? Mãe, gostaria que a senhora soubesse que se não fosse por você eu não teria chegado onde cheguei. Devo literalmente minha vida a você! Não consigo encontrar palavras para expressar o quanto sou grata. Seu amor incondicional desde o princípio me fez crescer, e hoje posso dizer que sou uma mulher realizada, pois, acima de tudo, tenho uma mãe maravilhosa! Te amo mamãe!

Pai Todo Poderoso, agradeço ao Senhor pela minha existência e pelas minhas conquistas. Finalizo pedindo ao Senhor que abençoe todas as pessoas com as quais tive a honra de conviver até os dias de hoje e as que eu ainda hei de encontrar daqui em diante. Amém.

Este trabalho dispôs do suporte financeiro das seguintes agências de fomento:  
Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e  
Conselho Nacional de Desenvolvimento Científico e Tecnológico  
(CNPq – processo no. 470442/01-8).

# SUMÁRIO

<i>Ficha Catalográfica</i>	ii
<i>Banca Examinadora</i>	iii
<i>Resumo</i>	v
<i>Dedicatória</i>	vii
<i>Agradecimentos</i>	ix
<b>1. INTRODUÇÃO</b>	<b>1</b>
1.1. Computação e Biologia	1
1.2. Sistemas Híbridos	4
1.3. Cognição e Cognição Dinâmica	5
1.4. Composição da Tese	8
<b>2. SISTEMAS COMPLEXOS: TAXONOMIA E UMA ESTRUTURA UNIFICADA DE DESCRIÇÃO</b>	<b>11</b>
2.1. A Ciência da Complexidade	11
2.2. Sistemas Complexos	13
2.2.1 Sistemas Dinâmicos, Equilíbrio e Caos	13
2.2.2 Entropia e Energia	18
2.2.3 Auto-Organização e Emergência	20
2.2.4 Conceituando Sistemas Complexos	23
2.3. Taxonomia dos Sistemas Complexos	25
2.4. A Necessidade de uma Estrutura Unificada de Descrição	28
2.4.1 Estrutura Unificada de Descrição (EUD)	30

<b>3. SISTEMAS COMPLEXOS ORGANIZADOS E SISTEMAS HOMEOSTÁTICOS</b>	<b>35</b>
3.1. Sistemas Complexos Organizados	35
3.2. Sistemas Homeostáticos Naturais	36
3.2.1 Homeostase	37
3.2.2 Sistema Nervoso	37
3.2.3 Sistema Imunológico	41
3.2.3.1. A Teoria da Rede Imunológica	42
3.2.4 Sistema Endócrino	45
3.3. Sistemas Homeostáticos Artificiais	47
3.3.1 Sistemas Homeostáticos Artificiais sob a Óptica da EUD	48
3.3.1.1. Redes Neurais Artificiais	48
3.3.1.2. Sistemas Imunológicos Artificiais	51
3.3.1.3. Sistemas Endócrinos Artificiais	54
3.3.2 Síntese dos Sistemas Homeostáticos Artificiais sob a Óptica da EUD	56
<b>4. SISTEMAS DE INTELIGÊNCIA COMPUTACIONAL</b>	<b>61</b>
4.1 Inteligência	61
4.2 Inteligência Computacional	62
4.3 Sistemas de Inteligência Computacional	63
4.4 Computação Evolutiva	64
4.4.1 Algoritmos Genéticos	65
4.4.2 Sistemas Classificadores com Aprendizado	68
4.4.2.1. O Sistema Classificador de John Holland	68
4.4.2.2. Exemplo Didático: Aplicação de um Sistema Classificador com Aprendizado para Desvio de Obstáculos em Navegação Autônoma	73
4.4.2.3. Outros Modelos de Sistemas Classificadores	76

4.4.2.4. Desafios e Perspectivas para os Sistemas Classificadores com Aprendizado	78
<b>5. UMA ABORDAGEM UNIFICADA PARA SISTEMAS COMPUTACIONAIS BIO-INSPIRADOS</b>	<b>81</b>
5.1. CLARINet: Uma Rede Imunológica de Classificadores	82
5.1.1 Fundamentos	83
5.1.2 Especificação do Modelo	84
5.1.3 Dinâmica da Rede	86
5.1.4 Algoritmo Resumido	90
5.2. Caso de Estudo: Robótica Autônoma	91
5.2.1 Robótica Autônoma: Um Desafio Cognitivo	92
5.2.2 Descrição do Problema	93
5.2.3 Um Cenário para Simulação	94
5.2.4 Modelagem do Problema	97
5.2.4.1. Codificação das Mensagens (Antígenos)	97
5.2.4.2. Codificação dos Classificadores (Anticorpos)	98
5.2.4.3. Exemplo de Codificação das Mensagens e dos Classificadores	98
5.2.5 Evolução e Aprendizado da Rede Imunológica de Classificadores	101
5.2.6 Resultados Preliminares	103
5.2.7 Análise do Experimento e Resultados	105
<b>6. PROJETO E SÍNTESE DE SISTEMAS HOMEOSTÁTICOS ARTIFICIAIS</b>	<b>109</b>
6.1. A Interação Neuro-Endócrina na Espécie Humana	109
6.2. Sistema Homeostático Artificial: Trabalho Anterior	113
6.2.1 Implementação da Rede Neural Artificial e do Sistema Endócrino Artificial	114

6.3. Sistema Homeostático Artificial: Uma Nova Proposta	118
6.3.1 Projeto das Redes Neurais Artificiais	118
6.3.2 Projeto do Sistema Endócrino Artificial	119
6.3.3 Dinâmica do Sistema	121
6.4. Aplicação: Robótica Autônoma	126
6.4.1 Experimento I	129
6.4.2 Experimento II	136
6.4.3 Experimento III	144
6.4.4 Experimento IV	149
6.4.5 Análise dos Experimentos e Resultados	155
<b>7. CONCLUSÃO</b>	<b>157</b>
7.1. Análise das Principais Contribuições da Tese	157
7.2. Perspectivas Futuras	158
7.2.1 CLARINet	159
7.2.2 Sistema Homeostático Artificial	160
7.2.3 Sistemas Computacionais Bio-Inspirados	161
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>165</b>
<b>APÊNDICE: TABELA DE ACRÔNIMOS</b>	<b>181</b>
<b>ÍNDICE REMISSIVO DE AUTORES</b>	<b>185</b>

# 1. INTRODUÇÃO

1. INTRODUÇÃO.....	1
1.1. Computação e Biologia.....	1
1.2. Sistemas Híbridos.....	4
1.3. Cognição e Cognição Dinâmica.....	5
1.4. Composição da Tese.....	8

Este capítulo estabelece motivações, contribuições e conceitos básicos vinculados ao desenvolvimento desta tese. De partida, busca-se correlacionar duas ciências: a computação e a biologia, retratando a atual interdependência existente e procurando ressaltar as possíveis vantagens dessa relação de troca. Em seguida, parte-se para a definição de conceitos relevantes a serem abordados no desenrolar dos outros capítulos, como sistemas híbridos, cognição e cognição dinâmica. Finalmente, encerra-se com a composição da tese, descrevendo resumidamente o conteúdo de cada capítulo, procurando ressaltar as principais contribuições deste trabalho.

## 1.1. Computação e Biologia

A computação como ciência é praticamente nova, mas ao longo dos últimos 50 anos desenvolveu-se e disseminou-se de forma espantosa. Pode-se dizer que dentre os nomes que mais contribuíram para esta ciência estão Alan Mathison Turing (1912-1954) e John von Neumann (1904-1958). Seus ensaios levaram à concepção do hoje tão utilizado computador eletrônico digital. Ambos também são considerados pioneiros da inteligência artificial (NILSSON, 1980; RUSSELL & NORVIG, 1995) e em pesquisas com vida artificial (LANGTON, 1995), além de terem participado na criação de uma ciência ligada ao estudo de sistemas complexos e crucialmente dependente da tecnologia da computação: a ciência da complexidade (COVENEY & HIGHFIELD, 1995).

A biologia é conhecida como a ciência da vida (PURVES *et al.*, 2001). Diferentemente da

ciência da computação, a biologia estabeleceu-se há séculos e é hoje considerada uma ciência madura e composta de inúmeras linhas de investigação, muitas vezes totalmente independentes. Com o crescente aumento da quantidade de informação disponível e demanda por resultados rápidos nas pesquisas, biólogos e outros cientistas da área renderam-se ao uso disseminado de computadores em boa parte de seus experimentos. Atualmente, é quase impossível conceber um laboratório da área de biomédicas sem a presença de um computador, seja para manipulação de imagens e dados, ou para realização de diagnósticos preliminares e controle de processos.

Documentos comprovam que Turing e von Neumann, considerados *pais* da computação e precursores da ciência da complexidade, despenderam um tempo considerável de suas pesquisas investigando fenômenos naturais em sistemas biológicos, procurando associá-los à computação (JEFRESS, 1967; COPELAND & PROUDFOOT, 2004). É possível compreender essa tentativa de vinculação recorrendo-se ao fato de que o estudo de sistemas complexos é intrínseco à biologia (HALL & HALLIDAY, 1998; PURVES *et al.*, 2001).

De fato, na ciência da computação existe um interesse crescente pelos estudos biológicos. Por exemplo, atentos à Lei de Moore, a qual profere que o poder de processamento dos computadores dobra em média a cada dois anos, os cientistas e engenheiros da computação procuram avidamente por alternativas à criação de chips (circuitos integrados) em pastilhas de silício, visto que se prevê que este tipo de material esgotará seu potencial de miniaturização em no máximo 10 anos. Recorrendo-se a formas alternativas de processamento de informação existentes na natureza, vários ensaios já estão sendo realizados em busca de um hardware biológico, empregando-se membranas (PAUN, 2002) ou DNA (ADLEMAN, 1994; PAUN *et al.*, 1998; ELOWITZ & LEIBLER, 2000; GARDNER, 2000).

O uso de matéria-prima biológica para o desenvolvimento de um novo tipo de hardware (biológico), conhecido como *wetware*, recebe a denominação de computação biológica ou computação com mecanismos biológicos (DE CASTRO, 2005). De forma equivalente, a progressiva busca por inspiração na biologia como metáfora para a criação de algoritmos computacionais voltados à solução de problemas é denominada hoje de *computação bioinspirada* ou *computação biologicamente inspirada* (SIPPER, 2002; DE CASTRO & VON ZUBEN, 2004; FORBES, 2004).

Tanto os computadores como as tarefas que eles desempenham estão se tornando cada vez mais complexos. A busca pela inspiração biológica e pelo hardware biológico justifica-se pelos comportamentos e características intrínsecos aos sistemas biológicos presentes na natureza, onde a maioria deles apresenta uma tendência à descentralização, capacidade de adaptação, escalabilidade, auto-organização e robustez. Esses aspectos, aliados a milhões de anos de evolução, são um convite à conquista e estabelecimento definitivo da sinergia entre a biologia e a computação (FORBES, 2004).

De acordo com SIPPER (2002), organismos naturais são sistemas complexos adaptativos e os produtos advindos da computação bio-inspirada e da computação biológica estão seguindo na mesma direção (DE CASTRO & VON ZUBEN, 2004). Como esta tese se dedica à proposição e implementação de sistemas computacionais bio-inspirados empregando o tradicional hardware de silício, decidiu-se que anterior à concepção destes sistemas seria imperativo o estudo atento dos sistemas complexos e dos principais conceitos básicos necessários a uma boa compreensão de seu comportamento. Dentre esses conceitos, que serão abordados no Capítulo 2, destacam-se: sistemas dinâmicos, equilíbrio, caos, entropia, energia, auto-organização e emergência.

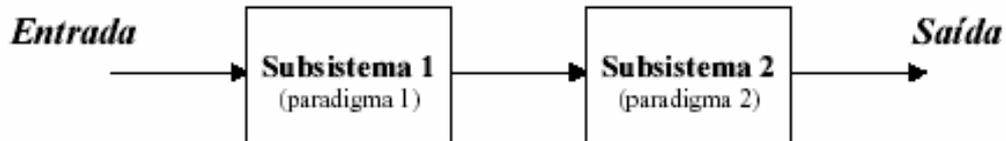
Esta conceituação individualizada de fundamentos básicos de sistemas complexos não implica que os mesmos serão explicitados ao longo da síntese e aplicação das propostas de sistemas computacionais bio-inspirados, as quais ocupam os capítulos subseqüentes do texto. Em lugar de uma descrição fundamentada diretamente em análise de sistemas dinâmicos, processamento de informação ou controle de processos, vislumbrou-se a possibilidade de se propor uma taxonomia circunstancial e, subseqüentemente, uma estrutura unificada para descrever estes sistemas (ainda no Capítulo 2 e ao longo do Capítulo 3). De posse dessas ferramentas, voltou-se o foco ao projeto e síntese de dois sistemas computacionais bio-inspirados, combinando paradigmas de inteligência computacional (Capítulo 4 e 5) com paradigmas advindos do conceito de homeostase artificial (Capítulos 3 e 6).

A união de paradigmas computacionais bio-inspirados ocorre através da hibridização de sistemas. Sendo assim, discorre-se a seguir sobre possíveis modos de hibridização.

## 1.2. Sistemas Híbridos

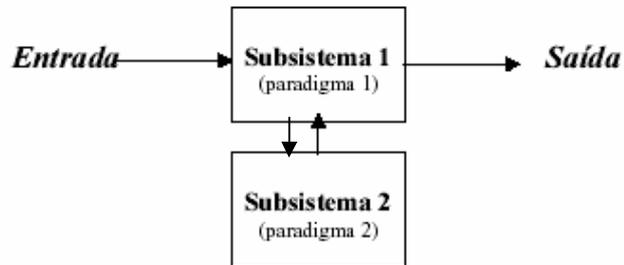
Em sistemas computacionais bio-inspirados, entende-se que um sistema híbrido é a combinação de duas ou mais técnicas de modelagem computacional, dando origem a um sinergismo (BUSHEV, 1994). Quando se cria um sistema híbrido, o objetivo é obter um sistema com menos deficiências e com um maior potencial, seja ele de interpretação, de aprendizado, de aplicação, de estimativa ou de generalização.

De acordo com VELLASCO e colaboradores (2004), existem três formas de integração de um sistema híbrido: 1) seqüencial; 2) auxiliar; e 3) incorporada. Na forma seqüencial, um paradigma, sob a conotação de subsistema, antecede o outro, ou seja, a saída de um subsistema serve como entrada para o seguinte (Figura 1.1). A forma seqüencial de integração apresenta-se como a forma mais fraca de hibridização, sendo às vezes sequer considerada como tal.



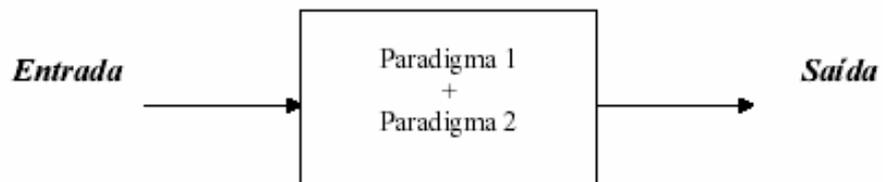
**Figura 1.1 – Esquema de um sistema híbrido seqüencial.**

Na forma de integração auxiliar, como o próprio nome sugere, um subsistema atua como auxiliar do outro. Em outras palavras, o subsistema principal solicita ao subsistema auxiliar a execução de determinada tarefa, o qual, após atender a solicitação, retorna o *controle* ao principal, ilustrado na Figura 1.2 pelas setas que ligam o subsistema 1 ao subsistema 2. Dessa maneira, a integração auxiliar apresenta um maior grau de hibridização do que a forma seqüencial, pois o subsistema principal *depende* do término da execução do subsistema auxiliar para terminar o seu processamento.



**Figura 1.2 – Esquema de um sistema híbrido do tipo auxiliar.**

Na terceira e última forma de integração, a forma incorporada, ocorre um nível alto de hibridização, pois não há separação perceptível entre os subsistemas que compõem o sistema híbrido. Pode-se dizer que um paradigma contém o outro e vice-versa (Figura 1.3).



**Figura 1.3 – Esquema de um sistema híbrido incorporado.**

Nesta tese, propõem-se abordagens unificadas para sistemas computacionais bio-inspirados, englobando sistemas de inteligência computacional e uma proposta de sistema homeostático artificial. Conforme será explicitado nos Capítulos 5 e 6, esses sistemas classificam-se como sistemas híbridos incorporados: embora seja perceptível a distinção entre os subsistemas, eles são hibridizados de forma a compor um sistema maior e mais sofisticado que requer a atuação conjunta dos subsistemas para promover ações mais eficazes.

### 1.3. Cognição e Cognição Dinâmica

O conceito de conexionismo está ligado à *ciência da cognição*, e refere-se à modelagem de fenômenos mentais e comportamentais empregando-se nós e conexões (FARMER, 1990),

como, por exemplo, redes neurais artificiais (HAYKIN, 1999). A esses modelos dá-se o nome de *modelos conexionistas ou em rede*.

Os principais modelos conexionistas a serem empregados nesta tese estão associados a uma abordagem particular para *cognição dinâmica*. Com isso, os conceitos de cognição e de cognição dinâmica apresentam-se como tópicos relevantes a serem abordados neste capítulo introdutório.

O estudo da cognição é central para o entendimento da mente humana, particularmente na busca de subsídios que permitam revelar como a mente funciona. Tentativas de se estudar a mente e sua operação ocorrem desde a Grécia antiga e seus filósofos (THAGARD, 1996). A partir daí, a tarefa do estudo da mente tornou-se uma ciência: chamada de ciência da cognição. De forma resumida, a ciência da cognição é o estudo interdisciplinar da mente e da inteligência (PFEIFER & SCHEIER, 1999).

Existem várias abordagens para o estudo dos processos mentais, entre elas destaca-se a abordagem dinâmica. Uma abordagem dinâmica para sistemas cognitivos busca interpretar os processos mentais em termos de sistemas dinâmicos, ou seja, equações que descrevem como a mente muda de estado ao longo do tempo, em lugar de adotar uma visão de processamento de informação e representação de conhecimento.

A plausibilidade desta abordagem dinâmica depende da capacidade de modelagem de aspectos relevantes do processamento mental. Iniciativas neste sentido são relativamente recentes, com a maior parte das publicações tendo ocorrido ao longo dos últimos quinze anos.

Podem ser definidas três diferentes abordagens dinâmicas para o estudo dos processos mentais (THAGARD, 1996):

1. Adoção de um conjunto reduzido de variáveis e equações: é a abordagem menos freqüente em virtude da dificuldade de aplicação direta de técnicas de modelagem bem-sucedidas na física e na biologia para a explicação de fenômenos cognitivos. É difícil identificar um conjunto reduzido de variáveis e equações capaz de explicar aspectos relevantes da cognição. No entanto, existem algumas propostas na literatura, no contexto de tomada de decisão (RICHARDS, 1990; BUSEMEYER & TOWNSEND, 1993) e de aquisição de linguagem (VAN GEERT, 1991).

2. Uso metafórico de conceitos de sistemas dinâmicos: na impossibilidade de

especificar explicitamente um conjunto de variáveis e equações capaz de descrever matematicamente fenômenos cognitivos, é ainda possível descrever os aspectos dinâmicos envolvidos recorrendo-se aos conceitos de espaço de estados, atratores e mudança de fase, por exemplo. THELEN & SMITH (1994) interpretaram os progressos de crianças em fase de aprendizado de como caminhar ereto em termos de transição entre estados atratores. Outras interpretações metafóricas de conceitos de sistemas dinâmicos foram realizadas no campo da psicologia clínica (SCHMID, 1991; BARTON, 1994).

3. Emprego de modelos conexionistas: trata-se da abordagem mais usual e que tem produzido os resultados mais relevantes. Sistemas conexionistas operam diretamente com modelos dinâmicos envolvendo sistemas de equações acopladas. O número de variáveis e de equações geralmente é elevado e o acoplamento está vinculado a conexões ponderadas. Os modelos matemáticos mais empregados são as redes neurais artificiais e as técnicas de neurociência computacional (O'REILLY & MUNAKATA, 2000; DAYAN & ABBOTT, 2001; TRAPPENBERG, 2002), com cada nó da rede correspondendo a um neurônio artificial e com as conexões associadas às ligações sinápticas entre os neurônios. Em particular, a neurociência computacional ocupa-se da modelagem do sistema nervoso, em muitos níveis estruturais, incluindo o nível biofísico (celular), de circuitos e de sistemas (CHURCHLAND & SEJNOWSKI, 1993). O estado de ativação dos neurônios geralmente envolve equações não-lineares e o padrão de acoplamento define o tipo de arquitetura da rede neural. Um dos modelos pioneiros e possivelmente o mais conhecido é a rede neural de HOPFIELD (1982), que pode ser descrita como uma estrutura conexionista totalmente interconectada e capaz de implementar memória associativa e operar com endereçamento por conteúdo, sendo que as memórias são diretamente representadas por pontos de equilíbrio no espaço de estados do sistema dinâmico não-linear resultante.

Os principais modelos cognitivos a serem empregados nesta tese estão associados à terceira abordagem para cognição dinâmica (VAN GELDER & PORT, 1995; VAN GELDER, 1995), embora não estejam restritos a arquiteturas de redes neurais artificiais. A síntese desses modelos

vai recorrer a uma abordagem *bottom-up*<sup>§§</sup>, fundamentada em simulação computacional e experimentos de controle autônomo de robôs móveis reais.

## 1.4. Composição da Tese

Esta tese está dividida em sete capítulos, como descrito a seguir.

O Capítulo 2 introduz os conceitos envolvidos na ciência da complexidade e, em seguida, propõe uma classificação circunstancial dos sistemas complexos. De posse da taxonomia proposta, mostra-se como se torna importante a definição de uma estrutura unificada de descrição destes sistemas, a qual será adotada no decorrer da tese como ferramenta não somente de descrição como também promotora da comparação e avaliação das diferenças entre os sistemas a serem analisados.

O Capítulo 3 inicia com uma conceituação de sistemas complexos organizados. Em seguida, se ocupa em descrever sucintamente os principais aspectos de três sistemas naturais do ser humano, capazes de operar visando a homeostase: o sistema nervoso, o sistema imunológico e o sistema endócrino. Essas descrições incluem a definição do termo homeostase e exposição de aspectos relevantes desses sistemas, a serem explorados em implementações computacionais. Segue a utilização da estrutura unificada de descrição, proposta no Capítulo 2, para apresentar as versões artificiais desses três sistemas: as redes neurais artificiais, os sistemas imunológicos artificiais e os sistemas endócrinos artificiais.

O Capítulo 4 ocupa-se em descrever dois sistemas de inteligência computacional. Para tal, inicialmente discorre-se sobre inteligência e inteligência computacional. Em seguida, aborda-se, dentre os vários tipos de sistemas de inteligência computacional, duas propostas da literatura: os algoritmos genéticos e os sistemas classificadores, os quais seguem a linha da computação evolutiva e serão partes constituintes do sistema híbrido a ser proposto no Capítulo 5.

Os capítulos 2, 3 e 4 também incluem revisões bibliográficas.

---

<sup>§§</sup> Modelos com abordagem *bottom-up* são aqueles cujo comportamento global emerge de um agregado de comportamentos simples provenientes somente de interações locais.

O Capítulo 5 apresenta uma abordagem unificada com base nos conceitos de sistemas híbridos incorporados e com ênfase na modelagem de sistemas computacionais bio-inspirados. A abordagem é híbrida por incluir sistemas de inteligência computacional e sistemas homeostáticos artificiais, através da união de dois paradigmas computacionais: os sistemas classificadores e os sistemas imunológicos artificiais. Com o intuito de se verificar o desempenho da nova ferramenta, faz-se uso da robótica autônoma como caso de estudo, apresentando-se resultados preliminares e uma subsequente análise do emprego desse novo paradigma a um problema específico de navegação autônoma de robôs.

O Capítulo 6 inicia com uma descrição de circunstâncias peculiares da interação do sistema nervoso com o sistema endócrino na espécie humana, estendendo conceitos expostos no Capítulo 3. Em seguida, descreve um dos trabalhos relevantes na área de sistemas homeostáticos artificiais, o qual apresenta uma proposta de uma versão artificial para um sistema endócrino. Segue-se a proposta de uma abordagem integrada de um sistema homeostático artificial envolvendo redes neurais artificiais e um novo modelo de sistema endócrino artificial. Apresenta-se, por fim, uma aplicação do sistema proposto em navegação autônoma de robôs, incluindo simulações computacionais e experimentos com robôs reais do tipo Khepera II<sup>®</sup>.

O Capítulo 7 contém uma análise das principais contribuições desta tese, seguida de sugestões e perspectivas futuras tanto para a área de sistemas computacionais bio-inspirados quanto para as ferramentas propostas.

## **2. SISTEMAS COMPLEXOS: TAXONOMIA E UMA ESTRUTURA UNIFICADA DE DESCRIÇÃO**

<b>2. SISTEMAS COMPLEXOS: TAXONOMIA E UMA ESTRUTURA UNIFICADA DE DESCRIÇÃO</b>	<b>11</b>
2.1. A Ciência da Complexidade	11
2.2. Sistemas Complexos	13
2.2.1 Sistemas Dinâmicos, Equilíbrio e Caos	13
2.2.2 Entropia e Energia	18
2.2.3 Auto-Organização e Emergência	20
2.2.4 Conceituando Sistemas Complexos	23
2.3. Taxonomia dos Sistemas Complexos	25
2.4. A Necessidade de uma Estrutura Unificada de Descrição	28
2.4.1 Estrutura Unificada de Descrição (EUD)	30

Neste capítulo, introduzem-se os conceitos envolvidos na ciência da complexidade e, em seguida, propõe-se uma classificação circunstancial dos sistemas complexos. De posse da taxonomia proposta, mostra-se como se torna imperativa a definição de uma estrutura unificada de descrição desses sistemas, a qual será adotada no decorrer da tese como ferramenta não somente de descrição como também promotora da comparação e avaliação das diferenças entres os sistemas analisados.

### **2.1. A Ciência da Complexidade**

Pode-se argumentar que é possível encontrar complexidade em quase todas as manifestações da natureza. Por este motivo, apesar de existirem definições variadas do termo na literatura, há um consenso de que a idéia de complexidade tem seus fundamentos na natureza e nos processos evolutivos. Para COVENEY & HIGHFIELD (1995), a complexidade é intrínseca à natureza. Por outro lado, existem autores, como Murray Gell-Man, citado por COVENEY & HIGHFIELD (1995), p. 357, e NICOLIS & PRIGOGINE (1989), que preferem vincular a definição de complexidade ao contexto ao qual ela se aplica. Por este motivo, NICOLIS & PRIGOGINE (1989)

abstêm-se o tempo todo de apresentar uma definição explícita do termo. Outros cientistas, como CHAITIN (1990), associaram o conceito de complexidade à computação, dizendo que *a complexidade de um algoritmo está vinculada ao uso de processamento (complexidade temporal) e memória (complexidade espacial)*.

O despertar da complexidade como ciência ocorreu no ano de 1928 em Viena, Áustria, com a tese de Ludwig von Bertalanffy (1901-1972), na qual ele descreve organismos vivos como sistemas (COWAN *et al.*, 1994). Outros de seus principais pioneiros foram Alan Mathison Turing (1912-1954) e John von Neumann (1904-1958). Ambos foram também precursores do hoje tão utilizado computador eletrônico digital. Com a computação digital, o estudo da complexidade e a simulação de comportamentos em sistemas complexos ganharam alguma tratabilidade. De acordo com COVENEY & HIGHFIELD (1995), *a ciência da complexidade está profundamente ligada e crucialmente dependente da tecnologia da computação*. A partir daí, surgiram vários trabalhos na área e diversos grupos de pesquisa se dedicaram à exploração do tema (COWAN *et al.*, 1994). Progressos significativos apareceram, e a ciência da complexidade ou o estudo dos sistemas complexos se estabeleceu em definitivo.

Assim como o termo complexidade, a ciência da complexidade também possui inúmeras definições na literatura. Dentre elas, COVENEY & HIGHFIELD (1995), p. 7, apresentaram um conceito formal dessa nova ciência: *a ciência da complexidade é o estudo do comportamento de coleções macroscópicas compostas por unidades básicas interagentes que possuem a habilidade potencial de evoluir com o tempo*. Os autores comentam que somente através de uma visão macroscópica é possível observar fenômenos coletivos coerentes, como *comportamentos emergentes* (o termo comportamento emergente em sistemas complexos será discutido na próxima seção).

Em linhas gerais, dentre outros objetivos, a nova ciência da complexidade procura demonstrar:

- o porquê o todo é maior do que a soma de suas partes; e
- como seus componentes se agrupam para produzir padrões globais.

A contribuição mais marcante da ciência da complexidade talvez seja a percepção de que boa parte dos fenômenos e processos naturais pode ser explicada, e às vezes reproduzida, seguindo-se algumas regras básicas simples e universais. A natureza é capaz de produzir estruturas complexas mesmo em situações simples e também pode obedecer a regras simples mesmo em situações complexas (GOLDENFELD & KADANOFF, 1999). Apesar do mundo ser complexo, as regras da natureza tendem a ser simples (COVENEY & HIGHFIELD, 1995), p. 277.

A seguir, procura-se conceituar sistemas complexos, introduzindo-se primeiramente vários conceitos preliminares.

## **2.2. Sistemas Complexos**

Com o intuito de facilitar o estudo dos sistemas complexos, alguns conceitos intrínsecos a estes sistemas serão apresentados a seguir, os quais são considerados relevantes à sua compreensão e, conseqüentemente, à compreensão das ferramentas a serem propostas mais adiante. São eles: sistemas dinâmicos, equilíbrio, caos, entropia, energia, auto-organização e emergência.

### **2.2.1 Sistemas Dinâmicos, Equilíbrio e Caos**

Um sistema é uma coleção de objetos unidos por algum tipo de interação ou interdependência. Cada objeto constituinte do sistema apresenta um conjunto de atributos relevantes que o descreve, sendo que o todo deve compor uma estrutura organizada.

Os sistemas podem ser classificados como abertos ou fechados. Para tornar viável esta classificação, supõe-se a existência de uma fronteira entre o sistema e o ambiente. De forma alternativa, talvez seja mais plausível considerar-se que um sistema não pode ser inteiramente fechado ou aberto, mas sim aberto a determinadas influências do ambiente e fechado a outras.

Originalmente, diz-se que um sistema fechado encontra-se isolado e não interage com o ambiente que o cerca (VON BERTALANFFY, 1968). Ele não possui entrada e é possível entender seu comportamento restringindo-se a uma análise interna. Um sistema pode ser fechado para matéria/energia, para informação, e/ou para organização.

Um sistema aberto é um sistema que interage com o ambiente e com outros sistemas através da absorção, da geração ou da troca de matéria, energia, informação e/ou organização (NICOLIS & PRIGOGINE, 1977). Ele recebe entradas e pode alterar seu comportamento em resposta a estímulos ou condições externas a suas fronteiras.

Organismos biológicos em geral são considerados sistemas abertos. Entretanto, eles são fechados para organização, ou seja, as mudanças em sua estrutura não são determinadas pelo mundo exterior. Em particular, no caso dos organismos biológicos, é patente e crítica para sua própria sobrevivência a manutenção de uma troca contínua de matéria e energia com o ambiente.

Sistemas podem ser estruturados hierarquicamente, isto é, eles podem ser compostos por diferentes níveis. Em um nível mais alto, tem-se a noção do todo, sem se atentar para detalhes de suas partes componentes. Em um nível mais baixo, observa-se uma quantidade de partes interagentes sem se compreender como se dá a organização que leva ao todo. Conforme mencionado na Seção 2.1, apesar de cada nível dentro da hierarquia possuir suas próprias leis, essas leis freqüentemente são simples e similares. Como será visto a seguir, os estudiosos dos sistemas ditos *dinâmicos* procuram modelar matematicamente as leis que regem as interações de seus componentes.

A representação matemática de um sistema equivale a determinar um conjunto de relações matemáticas entre os atributos dos objetos que compõem o sistema. Acredita-se que os sistemas complexos apresentam um comportamento *dinâmico* que é governado por leis evolutivas e particularmente similares (WEISBUCH, 1997). Faz parte dos objetivos da ciência da complexidade o estudo dessas leis evolutivas, as quais são determinadas pela natureza das interações de elementos individuais que compõem um sistema complexo (Seção 2.1). Desta forma, torna-se crucial a descrição das principais características dos sistemas ditos *dinâmicos*, visto que, como será explicitado a seguir, o estudo e análise da *dinâmica* de um sistema

complexo na maioria das vezes se dão pela representação matemática deste fenômeno (LUENBERGER, 1979). Além disso, THAGARD (1996) reforça que vários fenômenos em sistemas complexos podem ser entendidos de forma profícua em termos das idéias de sistemas dinâmicos, como: *espaço de estados, atratores, transição de fase e caos*.

Um sistema dinâmico é um sistema sujeito a mudanças ao longo do tempo, as quais podem ser caracterizadas por um conjunto de equações diferenciais (tempo contínuo) ou a diferenças (tempo discreto) que mostram como o valor atual de variáveis, capazes de representar o estado do sistema, depende matematicamente de valores passados destas mesmas variáveis e de entradas externas, sendo que estas últimas estão presentes apenas quando há interação com o mundo exterior. Essa dependência dos valores passados e de entradas externas pode ser constante (sistemas dinâmicos invariantes no tempo) ou variar no tempo (sistemas dinâmicos variantes no tempo). Além disso, essa dependência pode ser linear (sistemas dinâmicos lineares) ou não-linear (sistemas dinâmicos não-lineares).

O estado de um sistema dinâmico é definido como o conjunto de valores de grandezas físicas, denominadas variáveis de estado, necessário e suficiente para caracterizar univocamente a situação física deste sistema. Na prática, o número de variáveis de estado não apenas deve ser finito como também deve ser o menor possível, por questões de tratabilidade matemática. Sendo assim, é comum desprezar o efeito de um subconjunto de variáveis de estado na proposição de descrições aproximadas da dinâmica. Diz-se, assim, que a dinâmica é dominada pelas variáveis de estado remanescentes.

O número de variáveis de estado determina a ordem do sistema dinâmico. As variáveis de estado formam um vetor de estado do sistema dinâmico, de modo que uma instância do vetor de estados corresponde a um ponto no *espaço de estados*, cujos eixos de coordenadas estão associados diretamente às variáveis de estado e cuja dimensão é igual ao número de variáveis de estado, ou seja, à ordem do sistema dinâmico.

Como o estado pode variar ao longo do tempo, o ponto correspondente no espaço de estados vai descrever uma trajetória, a qual é parametrizada no tempo e indica o comportamento dinâmico do sistema a partir de um estado inicial. Na ausência de entrada externa e com

dinâmica invariante no tempo, esta trajetória no espaço de estados pode apresentar uma fase transitória e, em seguida, convergir para um comportamento específico, denominado comportamento de estado estacionário. Tanto para sistemas de tempo discreto como de tempo contínuo, o comportamento em estado estacionário de sistemas autônomos (sem entrada externa e com dinâmica invariante no tempo) pode convergir para um de quatro comportamentos possíveis (OTT, 1991):

1. ponto de *equilíbrio*: a trajetória é representada por um ponto no espaço de estados;
2. ciclo limite: a trajetória é representada por um circuito fechado no espaço de estados, implicando uma oscilação permanente;
3. quase-periodicidade: a trajetória é representada por um circuito quase-fechado no espaço de estados, ou seja, a razão entre os períodos de oscilação de cada par de variáveis de estado é irracional, impedindo o fechamento do circuito gerado pela trajetória;
4. *caos*: agrega todos os comportamentos da trajetória que não se encaixam nas definições anteriores.

Visto que a trajetória no espaço de estados de sistemas dinâmicos autônomos converge para um comportamento de estado estacionário, essas regiões do espaço de estados para onde a trajetória converge são denominadas *atratores*. Um sistema dinâmico linear autônomo vai apresentar um único atrator e este vai ser um ponto de equilíbrio. Já um sistema dinâmico não-linear autônomo pode apresentar qualquer um dos quatro tipos de atratores descritos acima, inclusive podendo apresentar todos ao mesmo tempo e em qualquer multiplicidade (OTT, 1991).

Neste caso, a convergência para um ou outro atrator vai depender da condição inicial do sistema, ou seja, do vetor de estados inicial. Na presença de entrada externa, é possível promover a migração da trajetória no espaço de estados de um atrator para outro. Este tipo de evento dinâmico é denominado *transição de fase*.

O *equilíbrio* é um estado que não pode ser alterado pela dinâmica do sistema. Uma

propriedade importante de um sistema em *equilíbrio* é a existência ou não de estabilidade. Em linhas gerais, a estabilidade de uma situação de equilíbrio está diretamente vinculada ao comportamento do sistema dinâmico quando este é submetido a uma perturbação.

O equilíbrio de um sistema pode ser caracterizado como instável, neutro ou estável. Um equilíbrio pode ser avaliado como estável somente se considerarmos a magnitude da perturbação que o sistema sofreu. Caso a perturbação exceda um determinado limite para um equilíbrio, a priori considerado estável, ela pode levar o sistema a um outro ponto de equilíbrio, que pode ser instável, neutro ou estável (KRIPPENDORFF, 1986). Como já foi mencionada, essa transição de estados é chamada de *transição de fase*. Não havendo transição de fase e sendo o ponto de equilíbrio assintoticamente estável, o estado produzido pela perturbação vai permanecer na bacia de atração do ponto de equilíbrio, e a trajetória vai convergir assintoticamente para o ponto de equilíbrio, cancelando assim o efeito da perturbação.

Em um equilíbrio dinâmico, um número de forças se complementa dinamicamente de forma que o comportamento do sistema é repetitivo, previsível, não gera novos estados, e a trajetória segue um ciclo regular (KRIPPENDORFF, 1986). Nada disso se verifica no caso do *caos*, em que a trajetória do sistema através do espaço de estados é caracterizada por uma extrema sensibilidade às condições iniciais, isto é, ínfimas mudanças no estado inicial podem produzir divergência completa no comportamento futuro. O matemático francês Henri Poincaré (1854-1912) teve uma participação decisiva no estudo desta sensibilidade às condições iniciais.

O termo *caos* foi utilizado pela primeira vez em 1975 por LI & YORKE (1975). Entretanto, suas propriedades já haviam sido observadas em 1960 pelo meteorologista Edward Lorenz (o criador do termo *Butterfly Effect*<sup>\*</sup>), quando o mesmo estava fazendo simulações meteorológicas em computador (PEAK & FRAME, 1998). Coloquialmente, caos significa “ausência de ordem”, confusão. No entanto, caos não é sinônimo de aleatoriedade, mas sim de reações previsíveis apenas em curto prazo. É por esse motivo que as trajetórias de um sistema caótico são, em geral, irregulares e causam a impressão de serem aleatórias, apesar de serem

---

<sup>\*</sup> O termo “Butterfly Effect” foi utilizado pelo meteorologista Edward Lorenz para descrever de forma poética o grau de sensibilidade de um sistema caótico a pequenas mudanças ou alterações em seu ambiente. Segundo ele: “o bater de asas de uma borboleta no Brasil poderia causar um tornado no Texas”.

governadas por forças determinísticas.

Contudo, a obtenção de comportamentos dinâmicos de natureza caótica não requer que a dinâmica seja determinística e nem mesmo que o sistema dinâmico seja autônomo. Sistemas dinâmicos estocásticos, variantes no tempo e/ou com entrada externa tendem a apresentar comportamentos temporais mais diversificados que sistemas autônomos determinísticos (KAPITANIAK, 1990).

Embora a dinâmica caótica não seja estritamente uma forma de evolução, trata-se de um importante aspecto a ser considerado no estudo do comportamento dos sistemas complexos. LANGTON (1990) propôs que os sistemas complexos emergem e se mantêm na “beira do caos”, um domínio estreito entre a constância inabalável e a turbulência caótica. O fenômeno “beira do caos” na conceituação de sistemas complexos será retomado na Seção 2.2.4.

### **2.2.2 Entropia e Energia**

O termo entropia deriva do grego “entropé”, ou mudança. O conceito de entropia é particularmente abstrato e, por este motivo, apresenta várias definições na literatura (HEYLIGHEN, 1992; COVENEY & HIGHFIELD, 1995; HONDERICH, 1995). Em linhas gerais, entropia é uma medida do nível de desordem ou falta de ordem de um sistema. A segunda lei da termodinâmica afirma que a entropia do universo (tomado como sendo um sistema fechado) está sempre crescendo. O físico austríaco Ludwig Boltzmann (1844-1906) expressou o significado da segunda lei de uma forma muito simples, por intermédio da equação  $S = k \cdot \ln(P)$ , onde a constante  $k$  é denominada constante de Boltzmann,  $S$  é a entropia,  $P$  é uma medida de probabilidade da ocorrência de um evento e  $\ln(\cdot)$  é a função logaritmo natural. A equação indica que quanto menos provável for um determinado evento, menor é a sua entropia (BERDICHEVSKY, 1997; HALLIDAY *et al.*, 2004).

Muitos autores afirmam que o evento menos provável de todos é o surgimento e a manutenção da vida, a qual, de acordo com a equação de Boltzmann, deve estar vinculada à menor entropia. No entanto, o físico austríaco Erwin Schrödinger (1887-1961) não considerou

razoável associar algo tão importante como a vida à minimização de uma grandeza. Sendo assim, ele propôs a negentropia, como o recíproco da entropia,  $1/S$ , de modo que a negentropia é máxima para as coisas vivas.

A vida não representa uma rejeição à segunda lei da termodinâmica. O físico britânico John Bernal (1901-1971) definiu em 1951 que a vida é um membro de uma classe de fenômenos que são abertos e de reação contínua, capazes de reduzir sua entropia interna às custas de matéria e energia livres tomadas do ambiente externo e subseqüentemente rejeitadas em uma forma degradada. Logo, a vida resulta de um processo auto-organizado, e VON FOERSTER (1960) enunciou que todo sistema que é auto-organizado (o papel da auto-organização em sistemas complexos será discutido ainda nesta seção) não pode ser fechado. Muitos outros cientistas propuseram equações matemáticas para descrever este processo termodinâmico aberto, de modo que o surgimento e a manutenção da vida podem conviver em harmonia com a segunda lei da termodinâmica (LEVY, 1992; DENBIGH, 2004).

Como conseqüência dessa linha de argumentação, para um melhor entendimento do estudo da entropia em sistemas complexos, é aconselhável recorrer-se às duas principais *leis* da termodinâmica, a qual é um ramo da física destinada à análise do armazenamento, transformação e dissipação de *energia*. Para os físicos, a entropia é medida em termos de energia ou calor. A energia pode ser definida como a capacidade de produzir trabalho (DE ROSNAY, 1998). Nesta tese, trabalho, no contexto de energia, também é sinônimo de *mudanças*. Como um exemplo, voltando-se ao conceito de equilíbrio em sistemas dinâmicos (Seção 2.2.1), para se extinguir um equilíbrio estável, ou provocar uma *mudança* no sistema, é necessária a adição de energia. Desta forma, a estabilidade de um sistema é tradicionalmente associada a estados de mínima energia, como pode ser atestado pela interpretação das duas leis fundamentais da termodinâmica.

A *primeira lei* da termodinâmica, ou lei da conservação, como o próprio nome sugere, afirma que a energia é sempre conservada, ou seja, a energia não pode ser criada nem destruída. Esta lei transformou a energia em um dos conceitos mais importantes em física.

A *segunda lei* da termodinâmica, ou lei da entropia, afirma que em todos os processos parte da energia envolvida perde irreversivelmente sua capacidade de produzir trabalho e,

portanto, encontra-se degradada em qualidade (denominada assim de *entropia termodinâmica*) (KRIPPENDORFF, 1986). Através desta segunda lei da termodinâmica, foi possível se aprofundar os estudos do conceito de dissipação de energia em sistemas complexos.

Seguindo esta linha de investigação, KONDEPUDI & PRIGOGINE (1998) aplicaram a termodinâmica do estado estacionário para desenvolver o que eles chamaram de *termodinâmica do estado não-estacionário*. Os fenômenos de redução de entropia via sistemas abertos foram então denominados de *estruturas dissipativas*, pois eles têm uma estrutura, mas não algo permanente como um sólido, e há dissipação de energia quando o suprimento de energia é interrompido. Fenômenos naturais como chuvas, redemoinhos e furacões, reações químicas específicas e a vida são exemplos de estruturas dissipativas, segundo essa perspectiva.

No entanto, as coisas vivas são tão mais complexas que outras estruturas dissipativas que o estágio atual de desenvolvimento da termodinâmica está longe de propor definições mais completas para a vida (LEVY, 1992; COHEN & STEWART, 1994; LOVELOCK, 1995). De modo incisivo, o físico francês Leon Brillouin (1854-1948) certa vez questionou: “Como é possível entender a vida quando o mundo inteiro é governado por uma lei como a segunda lei da termodinâmica, a qual aponta para a morte e aniquilação do universo?”.

O estudo recente do comportamento de estruturas dissipativas lembra a “lei da produção de entropia máxima” de SWENSON (1989), a qual descreve estruturas dissipativas e outras configurações consideradas longe do equilíbrio. Como foi mencionado, nessas configurações a estabilidade é dinâmica, de forma que o que é preservado não é um estado estático mas sim um processo ao longo do tempo (HEYLIGHEN, 1992).

### **2.2.3 Auto-Organização e Emergência**

É possível adotar o conceito de entropia para discorrer apenas sobre fenômenos organizados. De início, não se deve confundir organização com ordem. A palavra organização realmente pode remeter à noção de ordem. Na realidade, quando se caracteriza um sistema complexo como organizado pressupõe-se que este seja um sistema em que reina algum tipo de

ordem (DENBIGH, 2004).

Vários autores relacionam o crescimento da entropia com um processo de desorganização. Acredita-se que, com a crescente dissipação de energia e conseqüente aumento da entropia, a ordem tende a desaparecer (LEVY, 1992; KAUFFMAN, 1995). Contudo, adotando-se uma diferenciação entre ordem e organização, é aceitável postular que mudanças na quantidade de organização e na entropia de um sistema podem ocorrer de forma independente uma da outra (DENBIGH, 2004).

Muitos sistemas se tornam organizados pela atuação de comandos externos, exercidos por alguém capaz de operar com os aspectos locais e globais do referido sistema. No entanto, boa parte dos sistemas complexos se torna organizada devido à atuação de seus próprios processos internos, sem intervenção externa, sendo denominados sistemas *auto-organizados* (CAMAZINE *et al.*, 2001). Segundo HEYLIGHEN (1997), o fenômeno da *auto-organização* é basicamente um processo de *evolução* onde o desenvolvimento de estruturas novas e complexas acontece principalmente dentro e a partir do próprio sistema. Para LEVY (1992), enquanto um aumento de entropia dissolve a ordem, o fenômeno da *evolução*, apoiado pela *auto-organização* do sistema, promove a ordem.

Estruturas *auto-organizadas* são construídas somente a partir da interação de comportamentos simples desempenhados pelos indivíduos de um agregado. Além disso, o comportamento de cada indivíduo está fundamentado apenas em informações locais que ele é capaz de receber do meio.

Uma condição necessária para o fenômeno da *auto-organização*, também chamado de *extropia* (tendência dos sistemas de criar ordem a partir do caos) (LUCAS, 2003), é a ocorrência simultânea de processos de realimentação positiva e negativa (CAMAZINE *et al.*, 2001). O físico austríaco Heinz Von Foerster (1911-2002) chamou esse processo de “ordem a partir de ruídos”, ou “*order from noise*”, na literatura em inglês. Já o químico russo Ilya Prigogine (1917-2003), denominou-o de “ordem a partir de flutuações”, ou “*order by fluctuation*”, na literatura em inglês. De acordo com DE ROSNAY (1979), flutuações, oscilações, e ciclos podem levar ao nascimento de estruturas organizadas a partir da desordem.

Um último aspecto presente em estruturas organizadas e relevante à conceituação de sistemas complexos é a concepção de *emergência*. A emergência compreende *comportamentos* que *surgem* quando partes componentes de um sistema complexo *interagem*. Para John Holland (HOLLAND, 1998), a emergência é acima de tudo um produto de interações acopladas e dependentes de contexto. Para ele, a emergência centraliza-se nas interações que são mais do que a soma de atividades independentes. Desta forma, regras muito simples podem gerar *comportamentos emergentes* sofisticados.

De acordo com Andersson e colaboradores (ANDERSSON *et al.*, 2002) comportamentos emergentes são caracterizados por duas principais propriedades:

- 1) é difícil prever o comportamento global emergente apenas inspecionando as partes componentes;
- 2) é difícil decidir quais partes componentes utilizar para obter um comportamento emergente global específico.

Os autores ainda completam:

- o comportamento emergente é determinado de forma *bottom-up* (JOHNSON, 2001);
- as partes componentes que estão envolvidas na determinação do comportamento global são distribuídas;
- o comportamento global surge de determinações locais resultantes de comportamentos isolados de cada parte constituinte;
- comportamentos emergentes podem surgir em todos os níveis hierárquicos de um sistema.

Presume-se que esses comportamentos emergentes sejam a grande fonte da complexidade nos sistemas auto-organizados (PEAK & FRAME, 1998). Além disso, fenômenos emergentes persistentes podem servir como componentes de fenômenos emergentes mais complexos (HOLLAND, 1998).

Resumindo, *comportamentos emergentes* manifestam-se através de processos interativos simples e podem ser observados em qualquer sistema complexo, natural ou artificial (WILLIAMS,

1999). Na realidade, considerando as colocações de GREEN (1994), pode-se atestar que uma forte evidência do papel da emergência como geradora de complexidade está na biologia, onde a própria existência da vida justifica o papel fundamental que as interações, a auto-organização e o comportamento emergente desempenham em todos os sistemas biológicos.

A partir de 1990, a noção de emergência estendeu-se à computação com o advento da *computação emergente* (FORREST, 1990). O termo computação emergente refere-se aos sistemas computacionais nos quais comportamentos globais interessantes emergem a partir de várias interações locais. Acredita-se que somente através da computação emergente seja possível modelar comportamentos inteligentes no computador. De fato, FORREST (1990) afirma que a computação emergente é potencialmente relevante para diversas áreas, como sistemas adaptativos, processamento paralelo e modelagem cognitiva e biológica.

#### **2.2.4 Conceituando Sistemas Complexos**

Por um sistema complexo entende-se aquele cujas propriedades não podem ser entendidas ou explicadas estudando-se apenas suas partes constituintes (GALLAGHER & APPENZELLER, 1999). Esta é apenas uma das várias definições de sistemas complexos encontradas na literatura. Para WALDROP (1993), um sistema é caracterizado como complexo *por possuir um número vasto de agentes independentes interagindo entre si de inúmeras formas*. Já NICOLIS & PRIGOGINE (1989) preferem estudar os comportamentos complexos ao invés dos sistemas complexos. Eles acreditam que o estudo dos comportamentos complexos pode revelar algumas características comuns a sistemas de classes diferentes, o que pode permitir um maior entendimento da natureza desses sistemas.

Além da organização interna do sistema complexo, as interações do mesmo com o ambiente e as interações de seus componentes elementares são consideradas imprescindíveis ao seu entendimento. Outros aspectos importantes nessa investigação são a micro-estrutura interna, a capacidade de auto-organização e os processos de *seleção natural*. Uma visão puramente darwiniana sugere que a complexidade é um resultado direto da seleção natural

(DARWIN, 1859; 1993). Entretanto, a visão mais aceita pelos estudiosos desses tipos de sistemas é que a seleção natural apenas conduz o sistema através de um processo constante de adaptação e auto-organização (KAUFFMAN, 1993).

Ao se discorrer sobre sistemas complexos é fundamental considerar de que forma estes evoluem e/ou se adaptam, ou até o que provoca esta evolução e/ou adaptação com o tempo. Para tal, é importante introduzir o conceito de “beira do caos”.

Sucintamente, pode-se dizer que um *sistema aberto* que opera à *beira do caos* encontra-se em um estado longe do *equilíbrio*, onde a *entropia* do sistema é alta e existe uma busca constante pela *ordem* fora de suas fronteiras, dando origem ao surgimento de *comportamentos emergentes* e à conseqüente *auto-organização*.

De acordo com KAUFFMAN (1993), o conceito de “beira do caos” proporciona uma nova e poderosa ferramenta para se entender a evolução das espécies. Por exemplo, para KAUFFMAN (1993) um ecossistema sempre co-evolui para um estado à beira do caos, o que segundo COVENEY & HIGHFIELD (1995) conecta esta proposta ao conceito de *auto-organização crítica* de Bak (BAK, 1996).

O termo *auto-organização crítica* surgiu quando Per Bak, através do estudo de processos em estruturas dissipativas, como avalanches e terremotos, demonstrou que a maioria dos sistemas complexos espontaneamente evolui para o limite crítico entre a ordem (estabilidade) e o caos, onde o tamanho dos distúrbios obedece a uma lei poderosa: distúrbios menores são mais freqüentes que distúrbios maiores. A esse fenômeno, ele denominou *auto-organização crítica*, ou “*self-organized criticality*” na literatura em inglês.

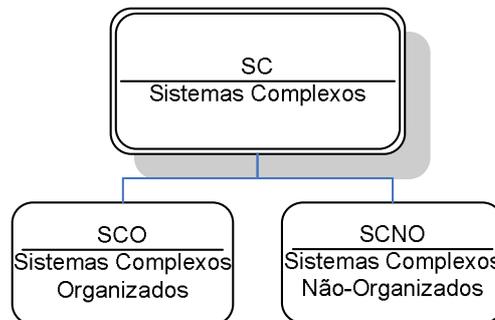
Conforme já mencionado na Seção 2.2.1, a existência do fenômeno de “beira do caos” é compartilhada por outros autores (LANGTON, 1990). De forma análoga, GOODWIN (1994) acredita que sistemas complexos que podem evoluir vão sempre estar à “beira do caos”, de maneira a favorecer o aparecimento de propriedades emergentes, as quais são essenciais ao processo evolutivo.

### 2.3. Taxonomia dos Sistemas Complexos

Existem na literatura inúmeras tentativas de classificação dos sistemas complexos. Entretanto, em nenhuma delas encontram-se regras bem definidas que possibilitem a inclusão direta de novos paradigmas. Sendo assim, propõe-se aqui uma classificação circunstancial e original, destinada tanto a promover a compreensão desses sistemas quanto a facilitar futuras inclusões seguindo esta proposta de classificação.

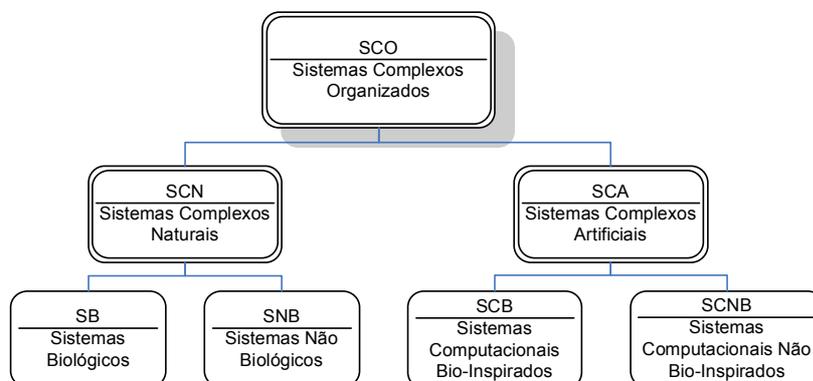
De partida, propõe-se dividir os sistemas complexos em dois grupos. O primeiro grupo compreende os sistemas complexos organizados (SCO). O segundo grupo compreende os sistemas complexos não-organizados (SCNO) (veja Figura 2.1).

É importante ressaltar que serão apresentados apenas os sub-ramos da árvore de classificação pertinentes ao escopo deste trabalho. Sendo assim, nenhum outro nível de classificação é apresentado junto aos sistemas complexos não-organizados (SCNO), por exemplo, pois estes fogem ao escopo do trabalho.



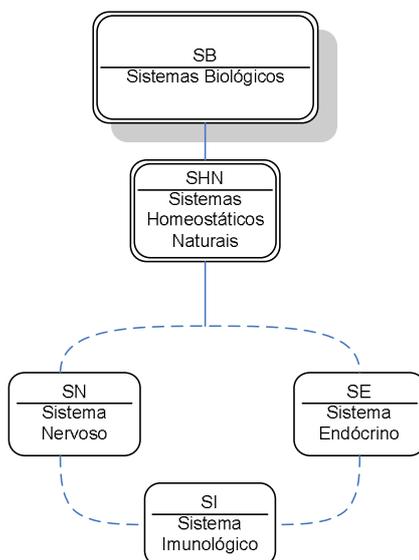
**Figura 2.1 – Divisão circunstancial dos sistemas complexos (SC) em organizados (SCO) e não-organizados (SCNO).**

Classificam-se dentro do grupo dos SCO os sistemas complexos naturais (SCN) e os sistemas complexos artificiais (SCA). Os SCN subdividem-se em sistemas biológicos (SB) e sistemas não-biológicos (SNB). Os SCA decompõem-se em sistemas computacionais bio-inspirados (SCB) e sistemas computacionais não bio-inspirados (SCNB) (veja Figura 2.2).



**Figura 2.2 – Divisão circunstancial dos sistemas complexos organizados (SCO) em naturais (SCN) e artificiais (SCA) e seus subsistemas.**

Seguindo-se a sistemática  $SC \rightarrow SCO \rightarrow SCN \rightarrow SB$ , destacam-se dentro dos sistemas biológicos (SB) os sistemas homeostáticos naturais (SHN). Por exemplo, o ser humano pode ser classificado como um sistema complexo, organizado, natural e biológico, além de ser composto por subsistemas que podem ser classificados como sistemas homeostáticos naturais. Neste trabalho, dar-se-á ênfase em particular ao estudo do sistema nervoso (SN), do sistema imunológico (SI) e do sistema endócrino (SE), conforme ilustrado na Figura 2.3.



**Figura 2.3 - Os sistemas nervoso, imunológico e endócrino, classificados circunstancialmente como um sistema homeostático natural.**

Os sistemas computacionais bio-inspirados, considerados como versões artificiais dos sistemas complexos organizados (Figura 2.2), também passam por uma subdivisão em dois grupos. O primeiro grupo, denominado sistemas de inteligência computacional (SIC), compreende todos os sistemas computacionais que têm como fonte de inspiração o ser humano, outros organismos vivos e suas formas de organização em sociedade. Classificam-se, por exemplo, neste grupo, as redes neurais artificiais (RNA) e a computação evolutiva (CE), a qual inclui os algoritmos genéticos (AG) e os sistemas classificadores (SC). No segundo grupo, classificam-se os sistemas que se inspiram nos sistemas homeostáticos naturais, com destaque para os seus processos de manutenção da homeostase. Este grupo foi denominado sistemas homeostáticos artificiais (SHA) e, nesta escala de classificação, encontram-se as redes neurais artificiais (RNA), os sistemas imunológicos artificiais (SIA) e os sistemas endócrinos artificiais (SEA) (Figura 2.4).

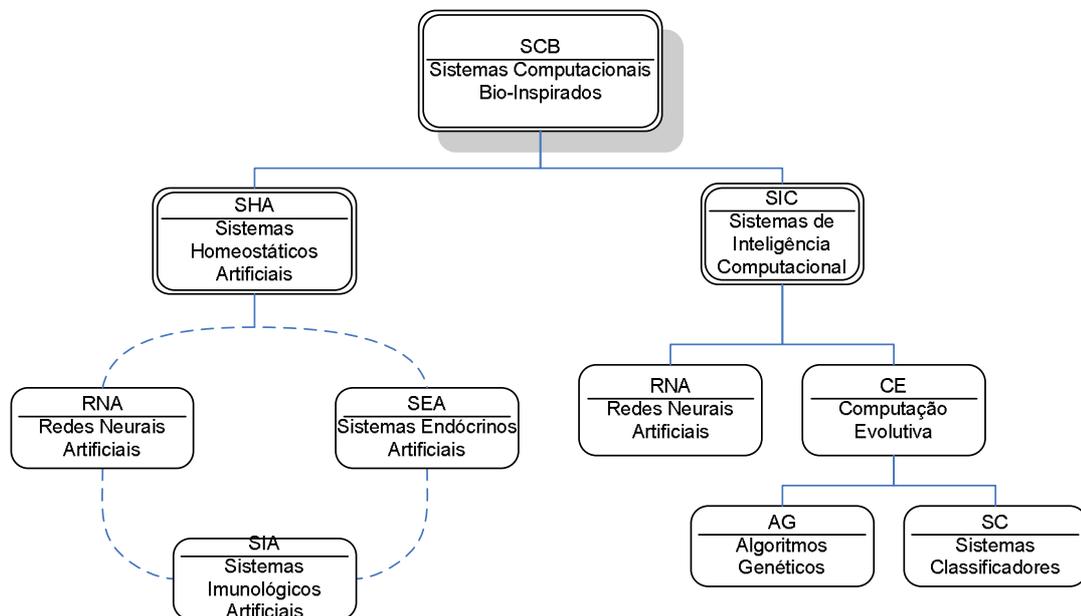


Figura 2.4 – Taxonomia circunstancial dos sistemas computacionais bio-inspirados.

Pode-se observar que, através da definição de regras claras de classificação, cria-se condições propícias para a classificação de qualquer outro paradigma computacional que envolva bio-inspiração. Por exemplo, a técnica de Otimização por Colônia de Formigas (ou “*Ant Colony Optimization*”, na literatura em inglês) é uma proposta de otimização computacional e seria classificada como um sistema de inteligência computacional (SIC), por ser inspirada no comportamento das colônias de formigas. Os Sistemas Nebulosos (ou “*Fuzzy Systems*”, na literatura em inglês) também seriam classificados como sistemas de inteligência computacional (SIC), pois têm como base o processamento de variáveis lingüísticas, o qual faz parte da cognição humana.

Esta proposta de classificação dos sistemas complexos não busca ser exaustiva nem tampouco impositiva ou estática. Por exemplo, as redes neurais artificiais, apesar de terem sido primeiramente classificadas como sistemas de inteligência computacional, também foram inseridas no contexto de sistemas homeostáticos artificiais, quando se tomou o processo homeostático como fonte de inspiração.

É importante explicitar que, apesar do conhecimento da existência de uma quantidade de sistemas complexos, buscou-se contemplar nesta seção apenas os sistemas que serão abordados neste trabalho. Acredita-se que esta proposta taxonômica circunstancial facilite o discurso futuro sobre estes sistemas ao longo desta tese, quando cada sistema será abordado individualmente e também em composições híbridas.

## **2.4. A Necessidade de uma Estrutura Unificada de Descrição**

Um sistema complexo pode apresentar uma estrutura modular e hierárquica. Entretanto, é possível decompor, estudar e entender suas partes separadamente, embora esta decomposição não seja produtiva para a compreensão do todo sem identificar e investigar as interações das partes.

Neste sentido, há décadas vários cientistas se esforçam para encontrar modelos universais capazes de representar estes sistemas de forma a facilitar o estudo, a compreensão e a

formulação de modelos dos mesmos. São inúmeros os ensaios com esse objetivo e esta tese restringir-se-á ao estudo e descrição de três propostas: a de Hermann Haken em 1969, a de John Holland em 1998 e a de Zibgniew Michalewicz e David Fogel em 2000.

Em 1969, Hermann Haken, em uma tentativa de formular leis universais válidas para modelar sistemas complexos e seus processos de auto-organização, propôs uma linha de pesquisa interdisciplinar denominada de Sinérgica, ou “*Synergetics*” na literatura em inglês (BUSHEV, 1994). A sinérgica propõe três níveis distintos de descrição de um sistema aberto: microscópico, mesoscópico e macroscópico (HAKEN, 2000). A criação dos modelos inicia-se com relações matemáticas abstratas, as quais em seguida são transformadas em equações que devem descrever explicitamente o sistema nos níveis microscópico, mesoscópico e macroscópico (HAKEN, 1996). Entretanto, Haken admite que mesmo os subsistemas podem se revelar muito complicados, o que torna difícil e às vezes inviável a tarefa de formular explicitamente equações microscópicas e mesoscópicas (HAKEN, 2000).

John Holland, por sua vez, procurou criar um modelo com base em agentes, o qual surgiu como um aperfeiçoamento dos sistemas classificadores (uma descrição de sistemas classificadores será apresentada no Capítulo 4). O modelo foi denominado de procedimentos geradores restritos ou “*Constrained Generating Procedures*” (CGP’s), na literatura em inglês (HOLLAND, 1998). Neste novo modelo, não existe a participação dos algoritmos genéticos, pois as próprias regras ou mecanismos são capazes de gerar ações e também de se auto-replicarem, criando uma hierarquia de agentes. Os mecanismos ou agentes são combinados através de outros procedimentos. Estes agentes combinados ou agregados geram um comportamento dinâmico. Entretanto, as interações dos agentes são limitadas, ou seja, suas ações, assim como as criações de novos agentes, sofrem restrições. Holland afirma que através deste modelo de agentes hierárquicos é possível observar o comportamento emergente de qualquer sistema.

Com ênfase na solução de problemas, MICHALEWICZ & FOGEL (2000) propuseram que anterior à solução de qualquer problema é pertinente observar três conceitos distintos, os quais destinam-se à formulação de técnicas heurísticas para solução de problemas. Estes conceitos são: a representação, a definição de um objetivo e a escolha de uma função de avaliação.

Cada uma das três propostas apresentadas acima possui suas vantagens e desvantagens. Entretanto, como será evidenciado a seguir, a presença de algumas particularidades complementares foi o motivo da escolha destas três propostas como fonte de inspiração, em detrimento de outras propostas da literatura. Além disso, esta iniciativa vai conduzir à criação de uma estrutura unificada capaz de descrever qualquer sistema em estudo recorrendo a um nível de detalhamento adequado ao interesse específico que motivou a descrição.

Em busca de uma estrutura unificada para descrever os sistemas complexos, procurou-se unir os três níveis de descrição empregados na sinérgica (HAKEN, 2000), com os conceitos de agentes propostos por HOLLAND (1998) e com as técnicas de formulação de problemas sugeridas por MICHALEWICZ & FOGEL (2000). Propõe-se então uma estrutura unificada capaz de descrever os sistemas complexos de uma forma sucinta e adequada aos propósitos desta tese.

Descrivendo-se os sistemas de acordo com esta estrutura, torna-se possível a identificação de seus componentes, suas interações internas e externas e suas fronteiras. Além disso, um dos objetivos desta tese é a proposição de sistemas híbridos, a qual pode ser melhor assimilada com a adoção de uma estrutura unificada de descrição.

### **2.4.1 Estrutura Unificada de Descrição (EUD)**

Quando se procura definir uma estrutura unificada de descrição, o objetivo é criar um mecanismo ou uma ferramenta capaz de descrever os sistemas complexos de uma forma sucinta e ao mesmo tempo abrangente, a qual possibilitará um estudo de seus componentes elementares e suas interações, assim como a emergência de comportamento inteligente e os mecanismos de auto-organização. Identificadas, todas essas características irão viabilizar uma compreensão mais abrangente dos sistemas híbridos a serem propostos nesta tese.

Utilizando-se de conceitos apresentados na Seção 2.2, a estrutura unificada de descrição (EUD) permite três níveis de descrição de um sistema complexo, como exposto a seguir:

**PRIMEIRO NÍVEL**, chamado de nível microscópico, onde se identificam e se descrevem os agentes do sistema, os quais representam os módulos elementares do modelo.

**SEGUNDO NÍVEL**, chamado de nível mesoscópico, onde se identificam e se descrevem as possíveis interações destes agentes.

**TERCEIRO NÍVEL**, chamado de nível macroscópico, onde se identifica e se descreve o sistema em um nível macro, considerando-o como uma agregação de agentes. Neste nível, devem-se identificar três itens:

- 1º – o tipo de energia que está sendo absorvida ou expelida pelo sistema;
- 2º – os procedimentos adotados pelo sistema para selecionar ou filtrar esta energia;
- 3º – os mecanismos que controlam as atividades do sistema em transição devido à entrada ou saída de energia.

Como um exemplo didático de emprego da proposta de estrutura unificada de descrição, analisa-se a seguir, cada nível de descrição juntamente com a aplicação imediata à descrição de um sistema complexo: *uma colônia de formigas* (CAETANO *et al.*, 2002).

O *primeiro nível* da EUD serve para se delimitar o grau de profundidade da descrição do sistema em questão. Neste ponto, é preciso definir quem serão, em princípio, as partes componentes elementares (os agentes) do sistema. Repare que os agentes não precisam ser do mesmo tipo, embora este seja o caso neste exemplo.

Colônia de Formigas: o componente elementar (ou *agente*) de uma colônia de formigas é a *formiga*.

Uma vez definidos quem são os agentes, o *segundo nível* é uma tentativa de identificar e explicitar as regras simples que normalmente governam as interações destes componentes elementares. É essencial a determinação dessas leis que regem as interações dos agentes, visto que as mesmas são a grande fonte dos *comportamentos emergentes* presentes no sistema. É oportuno ressaltar que as interações não necessariamente são do mesmo tipo, embora este seja o caso neste exemplo.

Colônia de Formigas: a forma mais comum de *interação* e comunicação entre os agentes do sistema é por meio de substâncias químicas voláteis (odor), solúveis (sabor) e de tato, chamadas de feromônios.

O objetivo principal do *terceiro nível* da EUD é a visualização macro do sistema, ou seja, do agregado de agentes. De acordo com HOLLAND (1998), interações de agentes produzem uma entidade agregada, ou seja, uma agregação de agentes, que é mais flexível e adaptável do que seus próprios componentes. Analisando o comportamento do agregado, é possível a identificação e o estudo dos fenômenos emergentes, da auto-organização e da dinâmica do sistema.

Este nível apresenta uma subdivisão em três itens, sendo que o primeiro item refere-se à energia consumida pelo sistema. Voltando-se ao conceito de energia, na Seção 2.2.2, falou-se que energia pode ser definida como a capacidade de produzir trabalho. Foi salientado também que este tipo de trabalho, no contexto desta tese, seria relacionado com *mudanças*. Desta forma, o terceiro nível utiliza a grandeza *energia* (item 1) com a intenção de simplificar a EUD, de modo que a energia possa representar todos os tipos de entrada do sistema macro, os quais apresentam-se como potenciais produtores ou promovedores de *mudança(s)* no sistema como um todo. Seguindo esse raciocínio, a energia neste conjunto pode ser informação, nutrientes, mensagens, outros agentes, etc.

Colônia de Formigas: as formigas absorvem *energia* do ambiente na forma de nutrientes, sejam de origem vegetal (formigas herbívoras), sejam de origem animal (formigas carnívoras) ou sejam de resíduos de substâncias ou restos (formigas detritívoras).

No item 2 deste terceiro nível, deve-se explicitar os processos seletivos ou de filtragem da energia absorvida pelo sistema. É importante lembrar que nem toda energia absorvida produzirá mudanças no sistema. Isto ocorre principalmente devido aos procedimentos de seleção e filtragem.

Colônia de Formigas: como as formigas vivem em sociedade, o processo de *seleção* de nutrientes é facilitado e caracteriza-se pela fase de *exploração* para descobrir a

localização do nutriente (este é um processo, em sua maior parte, solitário, onde cada agente explora o ambiente de forma independente dos outros, embora seguindo regras comuns e específicas de exploração).

Após a seleção e/ou filtragem da energia, o item 3 revela a(s) mudança(s) propriamente dita(s). Normalmente, os mecanismos que controlam as atividades do sistema em transição recorrem a processos evolutivos e de adaptação para lidar com os distúrbios, ruídos, perturbações, flutuações, oscilações, e ciclos provenientes da entrada ou saída de energia no sistema.

Colônia de Formigas: as sociedades das formigas são consideradas as mais complexas de todas as conhecidas no reino animal (CAETANO *et al.*, 2002). Após a *seleção* e localização do alimento, segue-se a fase de busca, caracterizada por um *sistema de recrutamento*. Apesar do processo de seleção e exploração possuir uma peculiaridade solitária, a fase de busca compreende de forma geral uma ação conjunta de um número de agentes que são *recrutados* dentro do ninho da colônia, pelo agente explorador, de forma a ajudar na coleta do nutriente selecionado. Portanto, pode-se articular que este sistema de recrutamento caracteriza um processo de *controle* das atividades da colônia quando da localização de nutrientes.

Posterior a esta análise e aplicação didática da EUD, é importante ainda ressaltar que a aplicação recursiva da EUD é intuitiva, fato que permite vários graus de abstração do sistema complexo sob estudo. Além disso, com o emprego da EUD é possível descrever um mesmo sistema complexo sob várias perspectivas, tanto com relação aos agentes do sistema (Primeiro Nível) e suas interações (Segundo Nível), quanto em relação aos itens de descrição do sistema macro (Terceiro Nível).

De posse dessa estrutura unificada de descrição, apresentam-se no Capítulo 3 exemplos de aplicação da EUD a três sistemas complexos: as redes neurais artificiais, os sistemas imunológicos artificiais e os sistemas endócrinos artificiais.

### **3. SISTEMAS COMPLEXOS ORGANIZADOS E SISTEMAS HOMEOSTÁTICOS**

<b>3. SISTEMAS COMPLEXOS ORGANIZADOS E SISTEMAS HOMEOSTÁTICOS</b> .....	35
<b>3.1. Sistemas Complexos Organizados</b> .....	35
<b>3.2. Sistemas Homeostáticos Naturais</b> .....	36
<b>3.2.1 Homeostase</b> .....	37
<b>3.2.2 Sistema Nervoso</b> .....	37
<b>3.2.3 Sistema Imunológico</b> .....	41
<b>3.2.3.1. A Teoria da Rede Imunológica</b> .....	42
<b>3.2.4 Sistema Endócrino</b> .....	45
<b>3.3. Sistemas Homeostáticos Artificiais</b> .....	47
<b>3.3.1 Sistemas Homeostáticos Artificiais sob a Óptica da EUD</b> .....	48
<b>3.3.1.1. Redes Neurais Artificiais</b> .....	48
<b>3.3.1.2. Sistemas Imunológicos Artificiais</b> .....	51
<b>3.3.1.3. Sistemas Endócrinos Artificiais</b> .....	54
<b>3.3.2 Síntese dos Sistemas Homeostáticos Artificiais sob a Óptica da EUD</b> .....	56

Este capítulo inicia com uma conceituação de sistemas complexos organizados e, em seguida, se ocupa em descrever sucintamente os principais aspectos de subsistemas homeostáticos naturais do ser humano: o sistema nervoso, o sistema imunológico e o sistema endócrino, a serem explorados em implementações computacionais. Segue a utilização da estrutura unificada de descrição (EUD), proposta no Capítulo 2, para apresentar as versões artificiais desses sistemas: as redes neurais artificiais, os sistemas imunológicos artificiais e os sistemas endócrinos artificiais.

#### **3.1. Sistemas Complexos Organizados**

De posse dos conceitos apresentados no Capítulo 2, Seção 2.2, pode-se estender a compreensão de sistemas complexos organizados. Estes sistemas são caracterizados como sistemas abertos e acredita-se que eles se “alimentam” de um tipo de energia ordenada (BUSHEV, 1994), ou seja, uma energia com baixa entropia que será utilizada para contrabalançar a tendência de degradação da energia interna do sistema. Entretanto nem toda energia que adentra

o sistema pode ser diretamente utilizada. Tal energia deve passar por um processo de seleção, o qual tem como base os objetivos específicos do sistema, objetivos estes normalmente relativos à sobrevivência e proliferação (DARWIN, 1859; 1993). A partir dessa energia “filtrada”, o sistema passa por um processo de mudança ou adaptação, caracterizado por atividades internas. Esse processo é coordenado por mecanismos de auto-organização, através de funções ou estratégias de transição, assim como mecanismos de realimentação.

Um sistema complexo organizado apresenta uma estrutura hierárquica e, portanto, é possível decompô-lo. Com isso, pode-se estudar e entender suas partes separadamente, embora esta iniciativa analítica não seja necessariamente produtiva para entender o todo (NICOLIS & PRIGOGINE, 1977; COVENEY & HIGHFIELD, 1995; BAK, 1996; GALLAGHER & APPENZELLER, 1999). Acredita-se que os organismos com maior gradação de inteligência são normalmente constituídos pela interação de vários sistemas complexos organizados, muitas vezes sem uma fronteira clara entre eles. Esses sistemas constituintes são passíveis de descrição apenas recorrendo-se a níveis hierárquicos de análise.

Neste contexto, descrevem-se a seguir três exemplos de sistemas complexos organizados existentes na natureza, apontados no Capítulo 2, Seção 2.3, como constituintes de um sistema homeostático natural. Defende-se aqui que cada um deles, tomado de forma isolada, também pode ser interpretado como um sistema homeostático natural, sem desprezar a existência de uma interdependência que melhor caracteriza a homeostase do organismo. Esses sistemas serviram de inspiração para a criação de suas versões artificiais e versões híbridas (com interdependência). São eles: o sistema nervoso, o sistema imunológico e o sistema endócrino.

### **3.2. Sistemas Homeostáticos Naturais**

Estudos biológicos comprovam que existe interconexão e dependência entre o sistema imunológico, o sistema nervoso e o sistema endócrino na espécie humana (BESENDOVSKY & DEL REY, 1996). Esta interação é fundamental para a manutenção do equilíbrio interno do organismo, chamado também de *homeostase*.

### 3.2.1 Homeostase

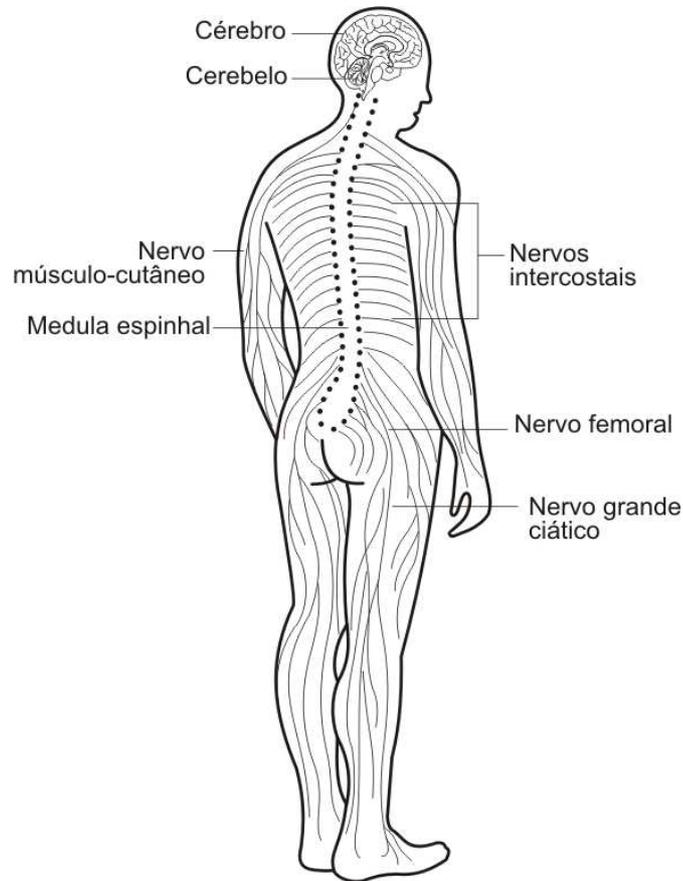
O termo *homeostase* ou *homeóstase* significa “propriedade auto-reguladora de um sistema ou *organismo* que permite manter o estado de *equilíbrio* de suas *variáveis essenciais* ou de seu meio *ambiente*” (FERREIRA, 1999). Há controvérsia sobre o primeiro aparecimento do termo na literatura. Segundo LEVINE (1998), o primeiro registro ocorreu com a publicação do trabalho de Cannon em 1929 (CANNON, 1929). Para PFEIFER & SCHEIER (1999) o termo *homeostase* foi completamente caracterizado por Ashby em 1960.

Independente de sua origem, existe o consenso de que o processo de *homeostase* está estreitamente ligado ao *equilíbrio* do sistema ou organismo e requer uma quantidade de receptores sensoriais especializados em detectar mudanças. No caso do corpo humano, esses receptores dão início a repostas específicas nos sistemas nervoso, imunológico e endócrino, os quais são os principais sistemas envolvidos diretamente com o processo de homeostase.

Existem estudos que apontam para a existência de um outro fenômeno biológico contrário à homeostase, chamado de *heterostase*. Este termo foi criado por KLOPF (1982), para descrever um tipo de comportamento que ele acredita existir na natureza em organismos que procuram estímulos constantemente, por exemplo, excitação ou prazer máximo e constante. Apesar da idéia de Klopff apresentar alguma consistência, a mesma encontrou forte contestação no ambiente científico, motivo pelo qual a hipótese de *heterostase* não será considerada nesta tese.

### 3.2.2 Sistema Nervoso

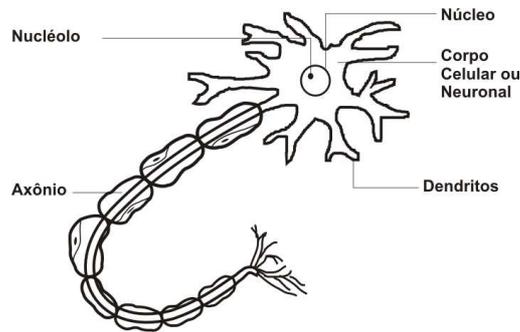
Entre outras funções, o sistema nervoso (SN) é responsável pela percepção de estímulos, detectando mudanças tanto no ambiente interno quanto no ambiente externo ao corpo humano, através de seus nervos (veja Figura 3.1). Esses estímulos são processados e transmitidos por impulsos nervosos do e para o cérebro (onde ocorre o processamento) promovendo repostas apropriadas, por exemplo, à ativação de movimentos dos músculos (MCCLINTIC, 1975).



**Figura 3.1 – O sistema nervoso do corpo humano (adaptado de PURVES *et al.* (2001)).**

Com relação à anatomia, o SN divide-se em sistema nervoso central, composto pelo encéfalo e pela medula espinhal, e sistema nervoso periférico, o qual estende-se pelo restante do corpo. O sistema nervoso periférico pode ser dividido em parte motora e parte sensorial. A parte sensorial recebe informação dos diversos sensores e a parte motora transmite sinais para os músculos e glândulas. As glândulas fazem parte do sistema endócrino e serão descritas mais adiante, ainda neste capítulo.

Entre as células nervosas constituintes do sistema nervoso central, os dois tipos principais são os neurônios (veja Figura 3.2) e gliócitos. Existem aproximadamente 100 bilhões de neurônios em um organismo humano e suas principais funções são transmitir, processar, filtrar e armazenar os sinais de comunicação entre o cérebro e as outras partes do sistema nervoso.

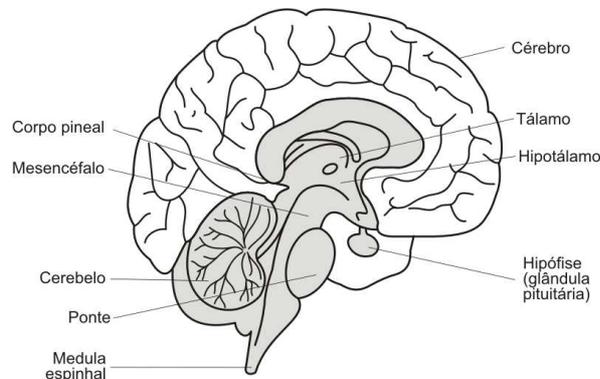


**Figura 3.2 – Principais componentes da anatomia de um neurônio (adaptado de PURVES *et al.* (2001)).**

As células nervosas chamadas gliócitos, ou glial ou da glia, compõem a chamada neurógliã, que é muito mais numerosa e representa metade do peso do cérebro. Ela é composta por células chamadas gliais ou da glia ou gliócitos. Ela é a estrutura de suporte do tecido nervoso, responsável por sustentar, proteger, isolar e nutrir os neurônios, assim como guiar o desenvolvimento de novos neurônios e controlar substâncias químicas envolvidas na comunicação célula a célula (MCCLINTIC, 1985). Nos neurônios, esta comunicação ocorre em um espaço entre as células, chamado de sinapse, trata-se de uma região de passagem do impulso nervoso de um neurônio para a célula adjacente, via uma operação eletroquímica. Estudos recentes apontam ainda para a participação de um gás denominado óxido nítrico ou NO - *Nitric Oxide*, na literatura em inglês, atuando como um neurotransmissor modular (Gally *et al.*, 1990; Hölscher, 1997).

O encéfalo decompõe-se em cérebro, cerebelo e tronco encefálico. O cérebro forma a maior porção do encéfalo e subdivide-se em diencefalo e telencefalo. No diencefalo, a região mais importante é o hipotálamo (veja Figura 3.3).

O hipotálamo é responsável por parte da expressão externa das emoções e pelo mecanismo de regulação do ambiente interno do corpo, processo conhecido como homeostase, o qual está relacionado com a sobrevivência do organismo (MCCLINTIC, 1985). No hipotálamo, ocorre a integração de vários padrões de comportamento envolvendo a correlação de funções neurais e endócrinas. Seus neurônios sofrem influência de uma variedade de hormônios e outras substâncias químicas circulantes (GUYTON & HALL, 1996).



**Figura 3.3 – Cérebro humano e suas divisões anatômicas (adaptado de PURVES *et al.* (2001)).**

Uma descoberta interessante da neurociência foi o fato de haver a possibilidade de modulação do sinal que é transmitido entre os neurônios através do ajuste das sinapses, o que permitiria ao cérebro adaptar-se a situações diversas. Acredita-se que este mecanismo seja a base para as associações, memória e várias outras habilidades mentais. Uma vez armazenadas no sistema nervoso, a partir de mecanismos que não serão explicitados aqui, as informações memorizadas tornam-se parte do processamento cerebral. O processamento de informação no cérebro recorre à comparação das novas experiências sensoriais com a memória armazenada, viabilizando a seleção de informação nova importante e a canalização para as áreas de armazenamento apropriadas, para uso futuro, ou para as áreas motoras, para causar respostas diretas (GUYTON & HALL, 2002). A plasticidade sináptica, ou seja, a capacidade de modificação das sinapses também é fundamental para a maioria dos modelos artificiais do sistema nervoso, de redes neurais (MCCLELLAND, ET AL., 1986; RUMELHART *et al.*, 1986; FAUSETT, 1994; HAYKIN, 1999) a modelos computacionais com base em neurociência (CHURCHLAND & SEJNOWSKI, 1994; O'REILLY & MUNAKATA, 2000; DAYAN & ABBOT, 2001).

Em suma, o sistema nervoso está constantemente em modificação e atualização. Virtualmente todas as suas funções, incluindo percepção, controle motor, regulação térmica e raciocínio, são modificáveis por experiência. A topologia dessas modificações parece não ser final ou terminada, mas sim um processo dinâmico e recorrente. Observações comportamentais ressaltam graus de plasticidade e hierarquia no sistema nervoso: existem mudanças rápidas e

superficiais, lentas e profundas, e outras aparentemente permanentes e ainda assim passíveis de modificação (GREGER & WINDHORST, 1996).

### **3.2.3 Sistema Imunológico**

O sistema imunológico (SI), em particular o sistema imunológico humano, é composto por uma grande variedade de células, moléculas e órgãos distribuídos pelo corpo. Assim como o sistema nervoso e o sistema endócrino, o sistema imunológico também está envolvido no processo de homeostase do organismo (JANEWAY *et al.*, 2000).

Existe um número vasto de teorias, princípios e processos desenvolvidos para explicar o comportamento do sistema imunológico e dos mecanismos de resposta imunológica. Esta subseção descreve os aspectos básicos do sistema imunológico, com ênfase na teoria da rede imunológica, pois um de seus vários modelos será adotado na composição de um dos sistemas híbridos a ser proposto no Capítulo 5.

O sistema imunológico age defendendo o organismo contra invasores externos e células com mau funcionamento que podem originar infecções. Esses agentes causadores de respostas imunológicas são denominados antígenos. No entanto, a denominada visão armamentista do sistema imunológico representa apenas uma das linhas de interpretação de seus mecanismos de operação, sendo que MATURANA & VARELA (1987) propõem que os mecanismos de operação dos organismos vivos, incluindo aqui o sistema imunológico, estão diretamente associados à cognição, de modo que adaptação e auto-organização, por exemplo, ocorrem continuamente, independente da presença de estímulos de origem externa.

Os principais componentes do sistema imunológico são o sistema imunológico inato e o adaptativo. O sistema imunológico inato é assim denominado pois o organismo nasce com a habilidade de destruir vários patógenos (ou microorganismos capazes de produzir doenças) já em um primeiro contato. Por outro lado, o sistema imunológico adaptativo utiliza receptores de antígenos, localizados em dois tipos de linfócitos (células imunológicas): células B e células T. Os linfócitos são pequenos leucócitos, ou glóbulos brancos de defesa presentes no sangue, que

possuem a maior responsabilidade dentro do sistema imunológico – indicar aos demais agentes do sistema imunológico a existência de antígenos.

Os tecidos e órgãos do sistema imunológico, sendo estes últimos conhecidos como órgãos linfóides, encontram-se distribuídos pelo corpo. Os órgãos linfóides dividem-se em primário (ou central) e secundário (ou periférico). Entre os órgãos primários, destaca-se o timo, o qual está diretamente envolvido na resposta imunológica através da maturação de células T. Já nos órgãos secundários, encerram-se os repertórios de linfócitos, os quais entrarão em contato com os antígenos nos linfonodos.

A adaptabilidade do sistema imunológico é facilmente ilustrada por procedimentos de vacinação, onde uma amostra do patógeno, inerte ou atenuado, é inoculada no organismo de forma que as células imunológicas responsáveis pelo reconhecimento deste agente específico são estimuladas a proliferar através de um processo conhecido como *seleção e expansão clonal* (BURNET, 1959). Durante esta proliferação, algumas células sofrem alteração em sua estrutura molecular devido a um processo regulado de mutação. Por esse motivo, pode-se concluir que o sistema imunológico “aprende” a combater certos agentes patogênicos alterando a estrutura molecular e a concentração de células individuais e de moléculas específicas no combate aos antígenos, caracterizando o desenvolvimento de um tipo de *memória* particular no sistema imunológico.

### 3.2.3.1. A Teoria da Rede Imunológica

Além da teoria de imunidade pela seleção clonal, existem outras teorias, dentre as quais se destaca a teoria da rede imunológica, a qual apresenta um grande potencial para aplicações de engenharia (DE CASTRO & TIMMIS, 2002). Basicamente, a teoria da rede imunológica propõe que o sistema imunológico é composto por um conjunto de moléculas e células que interagem por intermédio de propriedades físico-químicas de suas estruturas moleculares.

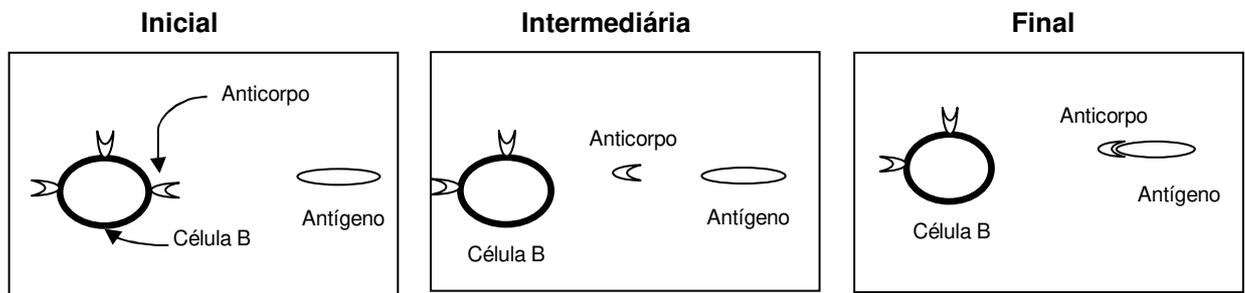
A dinâmica de auto-organização dessa rede é uma propriedade intrínseca do sistema imunológico e é resultado do reconhecimento mútuo entre células imunológicas, e entre células imunológicas e moléculas. Desta forma, os antígenos vão promover uma perturbação transitória

em um suposto estado de equilíbrio dessa rede de células e moléculas.

Uma característica importante das células imunológicas, responsável por promover resposta imunológica e também pelo entendimento da rede imunológica, é a presença de moléculas receptoras de superfície que se acoplam às estruturas moleculares dos antígenos.

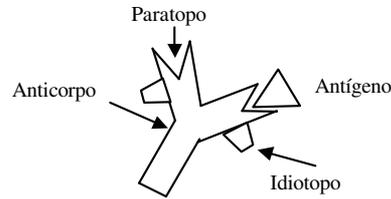
Particularmente, uma classe de células imunológicas, denominadas células B, pode aumentar sua concentração (em número de células) e modificar a estrutura de suas moléculas receptoras, denominadas anticorpos, de maneira a promover uma melhor eficiência no reconhecimento e na defesa contra infecções e reinfecções.

O reconhecimento antigênico ocorre pelo acoplamento de uma porção da superfície do antígeno com uma molécula receptora na superfície da célula imunológica, via interações físico-químicas. O grau de acoplamento entre as moléculas é chamado de afinidade. Quanto maior o grau de acoplamento, maior é a afinidade. A Figura 3.4 ilustra como uma molécula de anticorpo na superfície de uma célula B acopla-se ao antígeno.



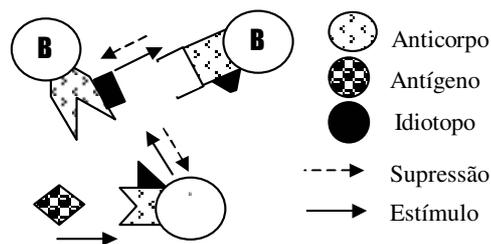
**Figura 3.4 Reconhecimento de um antígeno por uma molécula de anticorpo em uma célula B. Os formatos adotados fornecem apenas uma visão pictórica das interações físico-químicas efetivamente presentes.**

Na teoria da rede imunológica, proposta originalmente por JERNE (1974), anticorpos são capazes de reconhecer não somente antígenos mas também outros anticorpos. Deste modo, os anticorpos devem possuir alguns padrões moleculares em sua superfície, denominados idiotopos, os quais desempenham o papel de antígenos e, portanto, podem ser reconhecidos por outros anticorpos, conforme ilustrado na Figura 3.5.



**Figura 3.5** Anticorpos, suas porções moleculares e o reconhecimento antigênico. A porção do anticorpo que reconhece o antígeno é denominada paratopo, e a porção que pode ser reconhecida por outro anticorpo é denominada idioto.

Como os anticorpos reconhecem e podem ser reconhecidos por outros anticorpos, esta interação forma uma rede de comunicação dentro do sistema imunológico. Um aspecto interessante dessa teoria da rede imunológica reside no fato do sistema imunológico não depender do estímulo de antígenos externos para se manter em atividade. Portanto, a presença de suas próprias células e moléculas é suficiente para causar no sistema imunológico um comportamento dinâmico associado às interações que se estabelecem. Quando um anticorpo reconhece um antígeno ou outro anticorpo, ele é estimulado; caso o anticorpo seja reconhecido por outro anticorpo, através de seu idioto, ele sofre supressão. A Figura 3.6 ilustra este processo de estímulo e supressão.



**Figura 3.6** A teoria da rede imunológica. Quando um anticorpo reconhece um antígeno ou outro anticorpo, ele é estimulado; caso o anticorpo seja reconhecido por outro anticorpo, através de seu idioto, ele sofre supressão.

Um outro conceito importante é a meta-dinâmica da rede, a qual corresponde à inserção de novas células e moléculas na rede, e à morte seguida da remoção de células não estimuladas

da rede. A meta-dinâmica da rede modela uma operação natural do sistema imunológico, devotada à renovação celular em um organismo através da produção de novas células e eliminação de células danificadas, inúteis ou mortas.

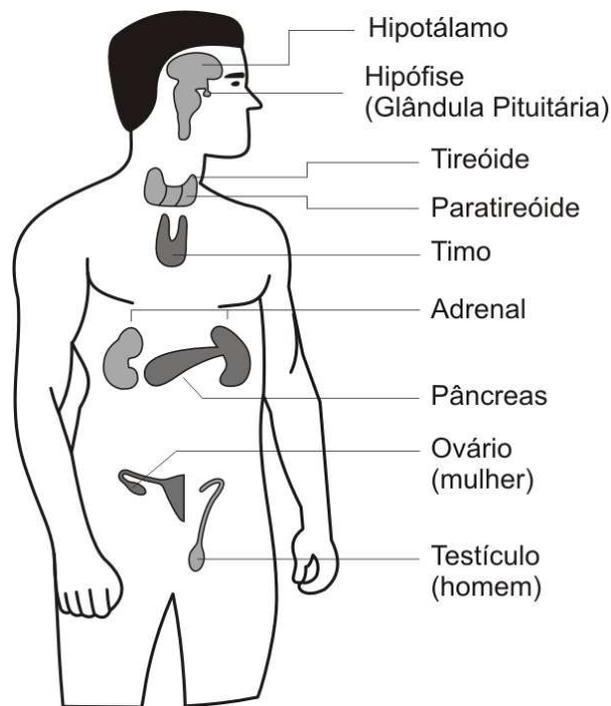
Para definir se uma das células geradas irá fazer parte da rede, é necessário determinar o nível de supressão ou estímulo de cada nova célula em relação às outras células da rede. O principal problema da teoria da rede imunológica é a falta de uma maior compreensão das etapas envolvidas nos fenômenos de supressão e estímulo da rede. Vários modelos matemáticos já foram propostos e esta tese se baseia em uma variação de um desses modelos, a ser apresentada mais adiante, na Seção 3.3.1.2.

### **3.2.4 Sistema Endócrino**

O sistema endócrino (SE) pode ser visto como um sistema de glândulas (veja Figura 3.7) que trabalha em conjunto com os sistemas nervoso e imunológico com o objetivo de controlar a atividade de órgãos internos e coordenar a resposta de longo-prazo a estímulos externos (PURVES *et al.*, 2001).

As principais funções do SE são contribuir para a manutenção da homeostase, regular o crescimento e a diferenciação celular, atuar no metabolismo, no desenvolvimento e na reprodução e ajudar o organismo a trabalhar em diferentes estágios de operação ou estados fisiológicos (GUYTON & HALL, 2002). Todas essas tarefas são realizadas pelos hormônios, os quais são substâncias químicas produzidas, armazenadas e secretadas pelos componentes do SE. Esses componentes podem ser um grupo de glândulas, células especializadas, tecidos do corpo e órgãos. Esses órgãos são, às vezes, também denominados glândulas.

Os hormônios são secretados na corrente sanguínea, sendo assim capazes de alcançar virtualmente todas as células do corpo. Desta forma, os hormônios podem provocar respostas específicas em células do corpo que estão em locais distantes da fonte de secreção. Substâncias semelhantes aos hormônios também são secretadas pelos neurônios (neurotransmissores) e células T do sistema imunológico (citocinas) (BESENDOVSKY & DEL REY, 1996).



**Figura 3.7 – As principais glândulas do sistema endócrino (adaptado de PURVES *et al.* (2001)).**

A secreção de um hormônio usualmente é provocada pela mudança no estado fisiológico do organismo e resulta em uma ação que tenta preservar o equilíbrio físico e químico do ambiente interno. Este mecanismo de retroalimentação reverte-se em um processo conhecido como manutenção da homeostase. O processo de homeostase opera por meio de uma gama de receptores sensíveis à detecção de mudanças. Esses receptores dão início a respostas específicas tanto no sistema endócrino como nos sistemas nervoso e imunológico.

Existem outros métodos que governam a produção e secreção de hormônios: nervos, produção de neuro-hormônios, presença de substâncias inorgânicas e orgânicas não hormonais no sangue e osmolaridade total do sangue (PURVES *et al.*, 2001). Como foi resumido por DE CASTRO & TIMMIS (2002), no sistema endócrino as respostas específicas a estímulos internos e externos acontecem em três etapas:

1. primeira: células nervosas sinalizam às glândulas endócrinas a presença de um estímulo;
2. segunda: as glândulas endócrinas secretam hormônios que carregam instruções

- destinadas a células que possuem proteínas de ligação específicas (receptores); e
3. terceira: o receptor da célula alvo interpreta a mensagem do hormônio, podendo causar assim a geração de novas proteínas ou alteração de proteínas celulares já existentes.

O nível de concentração dos hormônios é regulado por mecanismos de retroalimentação, os quais são essenciais para o bom funcionamento do organismo humano. Nesses mecanismos de retroalimentação, a mudança causada pelo hormônio pode servir também para regular a sua própria secreção ao longo do tempo.

### **3.3. Sistemas Homeostáticos Artificiais**

Nesta seção, descrevem-se três sistemas homeostáticos artificiais: as redes neurais artificiais, os sistemas imunológicos artificiais e os sistemas endócrinos artificiais. Estes sistemas fundamentam suas propriedades nos três sistemas homeostáticos naturais apresentados na seção anterior: o sistema nervoso, o sistema imunológico e o sistema endócrino. Salienta-se novamente que a homeostase num organismo humano se dá pela interdependência desses três sistemas, mas defende-se nesta tese a existência de propriedades homeostáticas em cada um, isoladamente, justificando assim a nomenclatura adotada.

O que levou a classificar esses sistemas como sistemas homeostáticos artificiais (SHA) (Capítulo 2, Seção 2.3), foi o fato dos mesmos emularem processos de controle e interação homeostáticos do corpo humano. A descrição dos SHA será realizada empregando a EUD (estrutura unificada de descrição) proposta no Capítulo 2, Seção 2.4.1.

Visto que a homeostase também pode ser alcançada pela interação desses três sistemas. Espera-se que o emprego da EUD auxilie no processo de identificação de aspectos complementares e pontos de interação desses sistemas, agora em suas versões artificiais.

### 3.3.1 Sistemas Homeostáticos Artificiais sob a Óptica da EUD

Quando se procura resolver um problema empregando sistemas computacionais bio-inspirados, o mais importante não é descrever *como resolver* o problema, mas sim descrever a forma *como se deve pensar* quando se tenta resolvê-lo. De forma particular, quando se descrevem sistemas computacionais bio-inspirados utilizando a EUD, procura-se evidenciar a maneira como os componentes elementares dos sistemas, os quais são denominados agentes, “operam”. Assim, torna-se prioritário o projeto desses sistemas para a solução de problemas de engenharia, que corresponde ao foco de atenção desta tese.

#### 3.3.1.1. Redes Neurais Artificiais

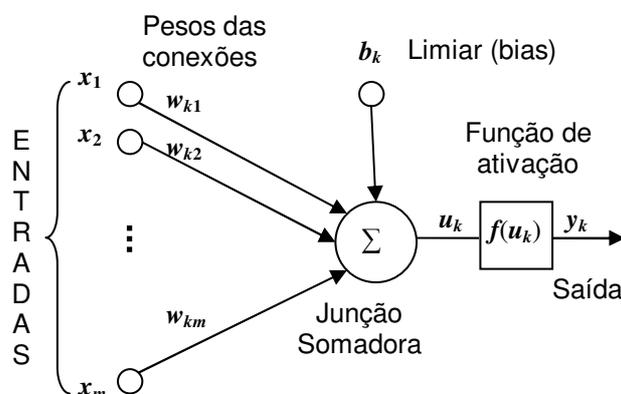
Empregando-se a EUD, temos:

##### PRIMEIRO NÍVEL

Uma rede neural artificial, como o próprio nome sugere, é formada por uma rede de neurônios artificiais. Portanto, pode-se dizer que o *agente*, ou componente elementar de uma rede neural é o *neurônio artificial*.

##### SEGUNDO NÍVEL

A interação ou base de troca de informações entre os neurônios artificiais dá-se por sinais numéricos, os quais são transmitidos entre neurônios através de conexões ou sinapses. Essas sinapses podem ser excitatórias ou inibitórias, tendo associado a si um peso sináptico ajustável. Veja um exemplo de neurônio artificial genérico na Figura 3.8, o qual é uma extensão realizada em 1958 por Rosenblatt de uma proposta de 1943 de McCulloch & Pitts (HAYKIN, 1999).



**Figura 3.8 – Neurônio genérico utilizado em RNA. Nesta representação, o índice  $k$  do peso sináptico  $w_{kj}$  corresponde ao neurônio pós-sináptico (o que está sendo representado) e o índice  $j$  corresponde a um dos neurônios pré-sinápticos.**

A Figura 3.8 ilustra as múltiplas entradas do neurônio genérico, representadas por  $x_i$ ,  $i = 1, \dots, m$ , e uma única saída  $y_k$  associada à função de ativação  $f(u_k)$ , onde  $u_k$  corresponde ao resultado do somatório dos produtos das entradas  $x_i$  pelos pesos sinápticos  $w_{kj}$  (incluindo o bias  $b_k$ ), conhecido como entrada líquida do neurônio.

A forma com que os neurônios artificiais estão conectados entre si define a arquitetura, ou estrutura, da rede neural, podendo ser uma estrutura em camadas, ou com total conexão entre todos os neurônios, ou ainda com outros padrões de conexão parcial, diretas e/ou recorrentes. A interação dos neurônios e, portanto, o comportamento da rede neural, dependerá diretamente desta arquitetura, ou seja, deste padrão de conexões.

### TERCEIRO NÍVEL

No contexto de RNA, ocorre *aprendizagem* ou *treinamento*, o que corresponde ao processo de ajuste dos parâmetros livres da rede através de um mecanismo de apresentação de estímulos ambientais, conhecidos como padrões (ou dados) de treinamento.

A maneira pela qual o ambiente influencia a rede em seu aprendizado define o paradigma de aprendizagem. Existem três paradigmas principais: aprendizado supervisionado, aprendizado não-supervisionado (ou auto-organizado) e aprendizado por reforço (HAYKIN, 1999; SUTTON &

BARTO, 1998). O aprendizado supervisionado é baseado em um conjunto de exemplos de estímulo-resposta (ou entrada-saída), ou em algum outro tipo de informação que represente o comportamento que deve ser apresentado pela rede neural. Neste caso, é possível avaliar o erro da rede neural para cada exemplo estímulo-resposta. O aprendizado não-supervisionado é baseado apenas nos estímulos recebidos pela rede neural. Basicamente, a rede deve aprender a “categorizar” os estímulos. Finalmente, no aprendizado por reforço, o comportamento da rede é avaliado apenas com base em algum critério numérico, fornecido em instantes espaçados de tempo, e que reforça ou penaliza o comportamento resultante. Neste caso, é possível dizer se a rede se comporta satisfatoriamente, mas não é possível avaliar diretamente o erro por ela cometido.

O objetivo do aprendizado em redes neurais é a obtenção de um modelo implícito do sistema em estudo, por ajuste dos parâmetros da rede. Por exemplo, dada uma rede neural artificial, seja  $w(t)$  um peso sináptico de um dado neurônio, no instante de tempo  $t$ . O ajuste  $\Delta w(t)$  é aplicado ao peso sináptico  $w(t)$ , gerando o valor corrigido  $w(t+1)$ , na forma:  $w(t+1) = w(t) + \Delta w(t)$ .

A obtenção de  $\Delta w(t)$  pode ser feita de diversas formas. O tipo de aprendizado é determinado pela técnica empregada no processo de ajuste dos pesos sinápticos (parâmetros da rede neural). Um conjunto bem definido de regras para obtê-los é denominado um algoritmo de aprendizagem ou treinamento. Como exemplos de alguns algoritmos, tem-se: a regra de Hebb e o algoritmo de retropropagação (“*backpropagation*”, na literatura em inglês).

Resumindo, de acordo com a EUD, neste terceiro nível de descrição identificam-se:

1º - o sistema absorve *energia* na forma de padrões (ou dados) de entrada.

2º - os paradigmas de aprendizagem definem a forma como a rede deve *selecionar* ou *filtrar* esta energia.

3º - algoritmos de aprendizagem são utilizados para controlar as atividades do sistema em *transição* devido à entrada de *energia* (padrões ou dados de entrada).

### 3.3.1.2. Sistemas Imunológicos Artificiais

Os sistemas imunológicos artificiais (SIA) podem ser definidos como sistemas complexos adaptativos (VARGAS *et al.*, 2002) inspirados pela teoria, funções, princípios e modelos imunológicos, os quais são aplicados na solução de problemas (DASGUPTA, 1999; DE CASTRO & TIMMIS, 2002).

Empregando-se a EUD, temos:

#### PRIMEIRO NÍVEL

Como componentes elementares deste sistema, identificam-se dois tipos: as células e as moléculas do sistema imunológico, que podem ser representados utilizando o espaço de formas (*shape-space*, na literatura em inglês) (PERELSON & OSTER, 1979). Um espaço de formas pode ser entendido como um espaço de representação onde vetores de atributos são utilizados como modelos abstratos para representar células imunológicas e moléculas.

#### SEGUNDO NÍVEL

Neste nível, dá-se ênfase às interações dos agentes do sistema. Um exemplo clássico que destaca essas interações está presente na teoria da rede imunológica e seus modelos matemáticos e/ou computacionais. Nesses modelos, procura-se descrever como as células e moléculas do sistema imunológico variam seu nível de concentração e estrutura molecular através do tempo, processo este conhecido como dinâmica da rede. Esta dinâmica ocorre pela troca de *sinais numéricos* de estímulo e supressão entre as células e as moléculas do sistema imunológico (os agentes do sistema). É evidente que deve se dar aqui um nível de abstração para possibilitar a representação computacional das interações, pois diferente do caso das redes neurais artificiais, as células e moléculas do sistema imunológico se movimentam por todo o organismo.

### TERCEIRO NÍVEL

Pode-se considerar um sistema imunológico artificial como uma agregação de células imunológicas que estão de prontidão para o combate a antígenos e agentes patogênicos. Este combate inicia-se com uma seleção interna dos indivíduos mais aptos a participar do processo. A seleção ocorre por funções de afinidade, que quantificam o grau de similaridade (reconhecimento) entre as células do sistema imunológico e os agentes patogênicos. Usualmente, este processo de seleção é conjugado a procedimentos posteriores de adaptação para auxiliar no combate aos agentes agressores.

Os procedimentos de adaptação em SIA são modelos simplificados de uma função, processo ou teoria imunológica. Por exemplo, a seleção clonal (BURNET, 1959), a seleção negativa (KRUISBEEK, 1995), a teoria da rede imunológica (JERNE, 1974), entre outras, têm sido largamente utilizadas pela comunidade dos SIA.

No caso particular da rede imunológica, geralmente esses modelos assumem uma seqüência de atributos para representar as células e moléculas, e utilizam equações diferenciais ordinárias, equações a diferenças ou procedimentos iterativos de adaptação para controlar a dinâmica e a meta-dinâmica da rede (DE CASTRO & TIMMIS, 2002). O modelo adotado neste trabalho para governar o comportamento de uma rede é uma variação do modelo proposto por Farmer e colaboradores (FARMER *et al.*, 1986).

Neste modelo, as células imunológicas e as moléculas (anticorpos) são representadas por seqüências de atributos binários de tamanho fixo. Somente as células B e os anticorpos são modelados, e como cada célula B possui um único tipo de anticorpo em sua superfície, nenhuma distinção é feita entre uma célula da rede e seu anticorpo. A Equação 3.1 é empregada para controlar a dinâmica do modelo de rede utilizado neste trabalho. Com base nesta equação, a concentração  $a_i$  de cada anticorpo é determinada considerando-se: a similaridade de cada anticorpo com o antígeno em questão, as conexões entre os anticorpos (as quais podem ser estimuladoras ou supressoras) e a taxa de morte natural dos anticorpos.

$$\frac{da_i(t)}{dt} = \left( \alpha \sum_{j=1}^N m_{ji} a_j(t) - \beta \sum_{k=1}^N m_{ik} a_k(t) + \lambda m_i - k_i \right) a_i(t), \quad \text{Equação 3.1}$$

onde:

- $N$  é o número de anticorpos que compõem a rede;
- $m_i$  é a afinidade entre o anticorpo  $i$  e um dado antígeno;
- $m_{ji}$  representa a afinidade entre o anticorpo  $j$  e o anticorpo  $i$ , em outras palavras, o grau de estimulação;
- $m_{ik}$  representa a afinidade entre o anticorpo  $k$  e o anticorpo  $i$ , em outras palavras, o grau de supressão;
- $k_i$  é a taxa de morte natural de  $a_i$ .

Finalmente, a Equação 3.2 é empregada para impor um limite superior ao nível de concentração de cada anticorpo, na forma:

$$a_i(t) = \frac{1}{1 + \exp(0,5 - a_i(t))} \quad \text{Equação 3.2}$$

Para viabilizar sua implementação computacional, o sistema de equações diferenciais acopladas na forma da Equação 3.1 deve ser aproximado por um sistema de equações a diferenças acopladas, empregando técnicas de cálculo numérico.

Resumindo, de acordo com a EUD e restrito aos conceitos vinculados à teoria da rede imunológica, neste terceiro nível identificam-se três itens:

**1º** – o sistema imunológico artificial absorve como *energia* os antígenos ou agentes patogênicos.

**2º** – as funções de afinidade permitem a quantificação do grau de reconhecimento entre as células do sistema imunológico (os agentes) e os agentes patogênicos (*energia*). Portanto, pode-se dizer que tal procedimento caracteriza um processo de *filtragem* dessa energia.

**3º** – os vários procedimentos de adaptação controlam o comportamento do sistema em *transição* devido à entrada de *energia* (agentes patogênicos) e determinam como este comportamento varia com o tempo.

### 3.3.1.3. Sistemas Endócrinos Artificiais

Os sistemas endócrinos artificiais fundamentam-se nos mecanismos para a manutenção da homeostase. Seu correspondente biológico é particularmente bem desenvolvido nos mamíferos. Como já foi mencionado na Seção 3.2.1, a homeostase do organismo é mantida por mecanismos de controle regulador que regem o comportamento do sistema.

Empregando-se a EUD, temos:

#### PRIMEIRO NÍVEL

As células glandulares, ou simplesmente glândulas, devem compor os principais elementos ou *agentes* do sistema endócrino artificial.

#### SEGUNDO NÍVEL

As *interações* destes agentes devem ocorrer por meio de troca de informações sobre o nível hormonal ou sobre o nível de outras substâncias no organismo. Especial atenção deve ser atribuída a alterações abruptas, intensas e prolongadas.

#### TERCEIRO NÍVEL

Um sistema endócrino artificial deve receber estímulos internos, que podem se apresentar como informação sobre o nível de concentração de determinados hormônios e de determinadas substâncias associadas, e estímulos externos, na forma de presença de alimento ou perigo iminente.

O nível desses estímulos internos e externos pode desencadear uma resposta endócrina. A resposta endócrina caracteriza-se pela liberação de hormônios das células glandulares. O próprio nível desses estímulos internos e externos pode servir para *moderar* o grau de reação do

sistema (retroalimentação positiva e/ou negativa). Este processo de moderação deve ocorrer de forma que o sistema endócrino artificial reaja aos estímulos internos e externos basicamente através do comportamento de suas células glandulares (ou glândulas). Em linhas gerais, a partir do início da liberação de hormônios, essas glândulas devem controlar sua secreção por meio do controle do nível de concentração dos hormônios (estímulo interno) e das substâncias vinculadas ao processo (estímulo externo).

A seguir, apresenta-se parte de uma tentativa de modelagem matemática para um sistema endócrino artificial presente na literatura (TIMMIS & NEAL, 2004). Mais detalhes serão apresentados no Capítulo 6.

Nesta proposta, o sistema endócrino artificial é composto por um agregado de células glandulares que secretam hormônios em resposta a estímulos externos (Equação 3.3 e Equação 3.4).

$$r_j = \alpha_j \sum_{i=1}^{nx} x_i \quad \text{Equação 3.3}$$

onde:

$r_j$  é a quantidade de hormônios liberada pela glândula  $j$ ;

$\alpha_j$  é a taxa de liberação de hormônios da glândula  $j$ ;

$x_i$  é a  $i$ -ésima entrada detectada pela glândula  $j$ ; e

$nx$  é o número total de entradas detectadas pela glândula  $j$ .

Dado que  $c_j(t)$  é a concentração de hormônio na glândula  $j$  no instante  $t$ , a variação desta concentração obedece a um decaimento geométrico:

$$c_j(t+1) = c_j(t) \times \beta \quad \text{Equação 3.4}$$

onde:

$\beta \in (0,1)$  é uma constante de decréscimo do decaimento geométrico.

Como foi evidenciado acima, essas equações procuram descrever o comportamento das

células glandulares, as quais devem secretar e monitorar a concentração de hormônios presentes no sistema e usar este valor para moderar o nível de reação ao estímulo externo.

Resumindo, de acordo com a EUD, neste terceiro nível temos:

1º – o sistema endócrino artificial absorve como *energia*, estímulos internos e externos.

2º – o controle do nível desses estímulos internos e externos faz parte do processo de avaliação adotado pelo sistema para *selecionar* ou *filtrar* os estímulos internos e externos (energia).

3º – a retroalimentação positiva e/ou negativa é o mecanismo que controla ou modera as atividades do sistema endócrino artificial em *transição* devido à entrada de estímulos internos e externos (energia).

### **3.3.2 Síntese dos Sistemas Homeostáticos Artificiais sob a Óptica da EUD**

Esta seção dedica-se à síntese dos três sistemas homeostáticos artificiais descritos nas seções anteriores utilizando a estrutura unificada de descrição (EUD). Como mencionado no Capítulo 2, Seção 2.4, o objetivo da EUD é tornar-se uma ferramenta capaz de descrever os sistemas complexos de uma forma sucinta e ao mesmo tempo abrangente. Esta estrutura possibilita um estudo dos componentes elementares do sistema e de suas interações, o que pode contribuir junto a etapas futuras de análise de comportamentos complexos, assim como facilitar uma análise futura da emergência de comportamento inteligente e os mecanismos de auto-organização. Outras vantagens da EUD estão presentes na facilidade de comparação de paradigmas distintos e na concepção de arquiteturas computacionais.

A Tabela 3.1 resume a descrição dos três sistemas homeostáticos artificiais: as redes neurais artificiais (RNA), os sistemas imunológicos artificiais (SIA) e os sistemas endócrinos artificiais (SEA), sob a perspectiva da EUD.

Em DE CASTRO & TIMMIS (2002), os autores descrevem algumas similaridades e diferenças entre os sistemas nervoso, imunológico e endócrino do ser humano.

**Tabela 3.1 – Resumo da Descrição dos Três Sistemas Homeostáticos Artificiais, RNA, SIA e SEA, sob a Óptica da EUD.**

EUD	RNA	SIA	SEA
<b>Primeiro Nível</b> (agentes)	neurônios artificiais	células e moléculas imunológicas artificiais	glândulas artificiais
<b>Segundo Nível</b> (iterações de agentes)	sinais numéricos de ativação, modulados pelas conexões sinápticas.	sinais numéricos de estímulo e supressão	sinais numéricos de nível hormonal ou nível de outras substâncias do domínio
<b>Terceiro Nível</b> <b>1º</b> - (tipo de energia absorvida)	o sistema absorve <i>energia</i> na forma de padrões (ou dados) de entrada, capturados por neurônios sensoriais.	o sistema absorve <i>energia</i> na forma de estímulos providos pelos antígenos ou agentes patogênicos, pelas células apresentadoras de antígenos e pelas células sinalizadoras.	o sistema absorve <i>energia</i> na forma de estímulos internos e externos, associados com variações de concentração e presença ou ausência de substâncias catalíticas.
<b>2º</b> - (procedimentos de seleção e filtragem)	os paradigmas de aprendizagem definem a forma como a rede deve <i>selecionar</i> ou <i>filtrar</i> padrões (ou dados) de entrada (energia).	as funções de afinidade caracterizam um processo de <i>filtragem</i> dos antígenos ou agentes patogênicos (energia).	o controle do valor do nível destes estímulos internos e externos faz parte do processo de avaliação adotado pelo sistema para <i>selecionar</i> ou <i>filtrar</i> os estímulos internos e externos (energia).
<b>3º</b> - (mecanismos que controlam as atividades do sistema em transição)	algoritmos de aprendizagem são utilizados para moldar as atividades do sistema em <i>transição</i> devido à entrada de <i>energia</i> (padrões ou dados de entrada).	os vários procedimentos de adaptação controlam o comportamento do sistema em <i>transição</i> devido à entrada de <i>energia</i> (agentes patogênicos) e determinam como este comportamento varia com o tempo.	a retroalimentação positiva e/ou negativa é o mecanismo que controla ou modera as atividades do sistema endócrino artificial em <i>transição</i> devido à entrada de estímulos internos e externos (energia).

Algumas dessas similaridades podem ser estendidas para as implementações computacionais desses sistemas e foram evidenciadas pela aplicação da EUD (Tabela 3.1). Por exemplo:

- 1) a existência de *interconexão*, presente na interação dos agentes dos sistemas;
- 2) a resposta apropriada a uma grande variedade de estímulos, evidenciada nos procedimentos de seleção e filtragem de energia. No caso das RNA, paradigmas de

aprendizagem aplicados sobre os padrões de entrada; nos SIA, funções de afinidade em relação aos agentes patogênicos; e, nos SEA, processos de avaliação do nível de estímulos internos e externos;

3) *a maturação do sistema e a adaptação*, comprovadas pela presença de mecanismos que controlam as atividades do sistema em transição. Para as RNA, os algoritmos de aprendizagem; para os SIA, os vários procedimentos de adaptação existente nos algoritmos imunológicos; e para os SEA, a presença de retroalimentação positiva e negativa.

As diferenças entre os três sistemas ocorrem em menor escala e também podem ser enumeradas. Basicamente estão relacionadas com:

1) *anatomia*, no caso das implementações computacionais, *a codificação dos agentes*. Nas RNA, tem-se os neurônios artificiais; nos SIA, os vetores no espaço de formas; e nos SEA, as glândulas artificiais;

2) *tipos de sinais de comunicação*, ilustrados na terceira linha da Tabela 3.1.

Além dessas comparações explícitas dos três sistemas fisiológicos (nervoso, imunológico e endócrino), estudos apontam para a existência de uma interconexão e dependência entre os mesmos, com o objetivo primordial de manter o estado interno do organismo (homeostase), a regulação imunológica e a defesa do organismo (BESEDOVSKY & DEL REY, 1996). Várias evidências dessas interações estão presentes no corpo humano, como a existência de receptores para troca de produtos específicos de cada sistema, a coexistência desses produtos nos tecidos, e a presença de mediadores do sistema endócrino e do sistema nervoso que podem afetar o sistema imunológico, dentre outras interações. Do mesmo modo, a comunicação entre os sistemas pode ser local ou ocorrer em circuitos cíclicos longos.

Uma vez que os mecanismos presentes nos três sistemas podem afetar uns aos outros, pode-se articular que existe uma operação de uma rede de interações entre os três maiores sistemas fisiológicos do corpo humano (BESEDOVSKY & DEL REY, 1996). Desta forma, para entender melhor esta operação no mundo computacional, a partir da análise da EUD de cada sistema pode-se idealizar um supersistema, ou seja, um único sistema complexo organizado

composto por três sistemas componentes (RNA, SIA e SEA), os quais trocam continuamente informações e sinais em busca da manutenção da homeostase de um organismo artificial.

Tendo em vista que os três sistemas interagem e produzem um sistema homeostático amplo e elaborado, implementações computacionais híbridas também serão consideradas. Seguindo esta linha de raciocínio, as propostas híbridas desta tese, a serem discutidas nos Capítulos 5 e 6, investigam parte das possíveis composições dos diferentes tipos de homeostase artificial.

## 4. SISTEMAS DE INTELIGÊNCIA COMPUTACIONAL

4. SISTEMAS DE INTELIGÊNCIA COMPUTACIONAL .....	61
4.1 Inteligência .....	61
4.2 Inteligência Computacional .....	62
4.3 Sistemas de Inteligência Computacional.....	63
4.4 Computação Evolutiva.....	64
4.4.1 Algoritmos Genéticos.....	65
4.4.2 Sistemas Classificadores com Aprendizado .....	68
4.4.2.1. O Sistema Classificador de John Holland.....	68
4.4.2.2. Exemplo Didático: Aplicação de um Sistema Classificador com Aprendizado para Desvio de Obstáculos em Navegação Autônoma.....	73
4.4.2.3. Outros Modelos de Sistemas Classificadores .....	76
4.4.2.4. Desafios e Perspectivas para os Sistemas Classificadores com Aprendizado.....	78

Este capítulo ocupa-se em descrever dois sistemas de inteligência computacional. Para tal, inicialmente discorre-se sobre inteligência e inteligência computacional. Em seguida, abordam-se, dentre os vários tipos de sistemas de inteligência computacional, duas propostas da literatura: os algoritmos genéticos e os sistemas classificadores, os quais seguem a linha da computação evolutiva e serão parte integrante de sistemas híbridos a serem propostos no Capítulo 5.

### 4.1 Inteligência

De forma geral, a solução de problemas complexos requer: a representação e modelagem das situações envolvidas, a determinação de objetivos mais específicos a partir de objetivos mais genéricos (GARDNER, 1993), a definição das decisões a serem tomadas visando a concretização dos objetivos, e o ajuste de parâmetros e estruturas de processamento de informação a partir da interação com o ambiente externo (PFEIFER & SCHEIER, 1999). Segundo MINSKY (1988), este elenco de habilidades cognitivas ajudam a caracterizar um ser inteligente.

É plenamente aceitável argumentar que nenhum organismo natural ou artificial, com

exceção do ser humano, atende aos requisitos de inteligência destacados acima, pois não se pode apontar qualquer organismo como capaz de operar com base em objetivos imediatos sejam eles genéricos ou específicos, ou seja, este organismo não pode ter plena consciência de suas ações. Neste sentido, nenhum ser vivo não-humano, assim como nenhum artefato artificial já concebido pelo ser humano, admitiria a adjetivação de inteligente. No entanto, muitos são os artefatos denominados de inteligência artificial e muitos são os organismos e colônias de organismos que se diz expressarem comportamento inteligente. São considerados inteligentes, portanto, quaisquer entidades capazes de emular comportamentos isolados típicos de seres humanos e qualquer organismo (ou coletivo de organismos) complexo organizado que expresse, em maior ou menor grau, um sub-conjunto das habilidades apontadas acima. Logo, é possível definir o grau de inteligência de um sistema natural ou artificial em termos do nível de atendimento do elenco de habilidades que caracteriza um ser plenamente inteligente. Entre os sistemas da natureza que podem exibir algum grau de inteligência, por menor que seja, encontram-se desde organismos pluricelulares até o ser humano.

Não faz parte do escopo desta tese investigar o grau de inteligência presente nos sistemas naturais e artificiais, até porque o enfoque da pesquisa está na emulação de comportamentos isolados típicos de seres humanos – como memorização, reconhecimento de padrões, aprendizado e adaptação –, a serem diretamente explorados em aplicações de engenharia envolvendo sistemas computacionais.

## **4.2 Inteligência Computacional**

Assim como o termo inteligência artificial (IA), o termo inteligência computacional (IC) é fonte de grande confusão e de definições díspares. A primeira definição formal foi enunciada em 1992 por BEZDEK (1992), o qual definiu inteligência computacional como sendo um processo cognitivo de baixo nível (processamento numérico) que procura reproduzir o funcionamento da mente humana. Em um segundo trabalho, em livro editado por Zurada e colaboradores no ano de 1994 (BEZDEK, 1994), o mesmo Bezdek buscou evidenciar a diferença entre a IA e a IC,

estendendo o conceito de IC e traçando as fronteiras entre as duas linhas de pesquisa, e destas com o que o autor chamou de inteligência biológica (IB). Em um outro trabalho com uma visão menos simplista e, portanto, mais plausível, POOLE *et al.* (1998) publicaram um livro no qual os autores definiram a IC como sendo o estudo da concepção de modelos de agentes inteligentes. Nesse mesmo trabalho, a IC foi classificada como uma sub-área da ciência cognitiva, abrangendo assim também o estudo do conhecimento.

Pode-se afirmar hoje que a IC é uma área de atuação derivada da ciência da computação, que procura inspiração no comportamento do ser humano considerando-se tanto os aspectos cognitivos quanto os aspectos evolutivos para criar ferramentas computacionais que apresentem um grau de inteligência em seu processamento de informação. Ela abrange várias linhas de pesquisa e ferramentas computacionais. Dentre estas, encontram-se as redes neurais artificiais, os sistemas imunológicos artificiais, os sistemas endócrinos artificiais e os sistemas nebulosos. Todas essas ferramentas e linhas de pesquisa constituem sistemas de inteligência computacional.

### 4.3 Sistemas de Inteligência Computacional

Em seu livro *Hidden Order*, HOLLAND (1995) inicia com uma discussão sobre como os sistemas naturais (biológicos e sociais) são formados e como são auto-sustentáveis. Dentre eles, vários exemplos foram citados, desde a cidade de Nova York, passando pelo sistema nervoso de um ser humano e o sistema imunológico dos vertebrados. Esses sistemas foram denominados por ele como *sistemas complexos adaptativos* (SCD), nos quais o comportamento do todo representa mais do que a simples soma de comportamentos isolados de suas partes constituintes.

Apesar das diferenças entre todos os sistemas complexos adaptativos e das várias definições divergentes encontradas na literatura para o mesmo termo, na maioria dos casos a caracterização do sistema tem como base alguns aspectos principais: 1) interações de componentes; 2) diversidade; e 3) adaptação. Os agentes que compõem um sistema complexo adaptativo interagem entre si e com o ambiente. Desta forma, novos comportamentos emergentes são gerados para o sistema como um todo.

A característica principal que distingue os SCD dentro dos sistemas complexos organizados é a sua capacidade de *adaptação*. Esta capacidade de adaptação permite que o sistema se torne mais apto a desempenhar determinada tarefa. Ela também está relacionada com a capacidade do sistema de processar informação (ou computar). As principais tarefas diretamente relacionadas à sustentação de integridade do sistema envolvem a coleta de informação do ambiente, o seu processamento, a tomada de decisão e a ação.

O processo de adaptação pode afetar um indivíduo direta ou indiretamente. Por exemplo, os efeitos “estigmergéticos” (GRASSÉ, 1959; HOLLAND & MELHUISH, 1999) observados em sociedades de insetos são os que promovem a adaptação ao ambiente como decorrência da ação isolada de agentes sobre este mesmo ambiente, o que de fato ocasiona padrões de comportamento diferentes para os próprios agentes. É importante ressaltar que um aumento na complexidade do processo de interação de agentes resulta em um aumento nas possibilidades de surgimento de fenômenos *emergentes* (HOLLAND, 1998).

Uma das principais questões que envolvem os sistemas complexos adaptativos se refere a como um sistema descentralizado (sem um planejamento central) pode ser auto-organizado. Neste sentido, em busca de alternativas para uma melhor compreensão e estudo destes sistemas, vários cientistas propuseram e ainda propõem ferramentas computacionais com a capacidade de simular aspectos isolados e genéricos dos SCD. Essas técnicas artificiais foram denominadas nesta tese de *sistemas de inteligência computacional* (SIC).

A seguir, discorre-se sobre duas dessas ferramentas computacionais, as quais irão compor sistemas complexos adaptativos a serem propostos no Capítulo 5.

#### 4.4 Computação Evolutiva

A *computação evolutiva* (CE) foi definida por FOGEL (1995) como uma tentativa de se modelar processos evolutivos em computador. Sendo evolução e adaptação profundamente conexas e ambas ocorrendo em praticamente todos os sistemas naturais, classificou-se a CE, nesta tese, como parte dos sistemas de inteligência computacional (Capítulo 2, Seção 2.3).

De acordo com Fogel, a evolução caracteriza-se por atuar em diversos níveis hierárquicos. Por exemplo, ela pode ocorrer em um gene específico ou em uma espécie.

Com o propósito de simular evolução com ênfase no nível genético e cromossômico, John Holland formalizou duas técnicas de computação evolutiva, denominadas *algoritmos genéticos* (em 1969) (HOLLAND, 1992) e *sistemas classificadores* (em 1976) (HOLLAND, 1986). Esses dois paradigmas foram classificados, dentro da taxonomia proposta no Capítulo 2, como sistemas computacionais bio-inspirados (Capítulo 2, Seção 2.3). Discorre-se a seguir sobre a primeira técnica, os algoritmos genéticos.

#### 4.4.1 Algoritmos Genéticos

Os *algoritmos genéticos* (AG) são um tipo especial de algoritmo, pois definem um conjunto predeterminado e bem definido de regras e processos inspirados em mecanismos observados na natureza. Essas regras e processos são destinados à *busca estocástica polarizada* (ATMAR, 1994) da solução de um problema, com um número finito de etapas. Além do caráter estocástico ou aleatório dos algoritmos genéticos, eles são capazes de explorar com eficiência a memória passada, no sentido de polarizar a busca por regiões promissoras no espaço de candidatos à solução (GOLDBERG, 1989).

Os algoritmos genéticos baseiam-se principalmente nas teorias evolutivas apresentadas por DARWIN (1859; 1993), e nos processos evolutivos das espécies, especialmente no mecanismo de seleção natural. Descreve-se na Tabela 4.1 a correspondência entre alguns termos da linguagem adotada em ambiente computacional e na biologia.

De forma simplificada, os passos básicos do processo de execução de um algoritmo genético podem ser descritos como um procedimento que recebe como entrada uma *população inicial* e uma função de avaliação, normalmente denominada função de *fitness*, e fornece como saída o melhor *indivíduo* encontrado após o processo evolutivo (variações em relação a este esquema podem ser encontradas na literatura).

**Tabela 4.1 - Correspondência entre o vocábulo biológico e o computacional**

Termos Biológicos	Termos Computacionais
Cromossomo	Indivíduo
Gene	Caractere ou atributo
Alelo	Valor do caractere
Lócus	Posição do caractere
Genótipo	Vetor de caracteres que representa o indivíduo
Fenótipo	Interpretação do vetor de caracteres

Mais detalhadamente, o algoritmo genético parte de uma *população* inicial e, através de um mecanismo de *seleção*, dá preferência aos indivíduos “mais adaptados ao ambiente” (que apresentam maior *fitness*) para aplicar os operadores genéticos de *crossover* e *mutação*. Caracteriza-se assim um processo evolutivo, onde se espera que o *fitness* do melhor indivíduo a cada geração apresente uma tendência de crescimento continuado, sendo este indivíduo, por conseguinte, capaz de representar uma boa solução do problema proposto, a qual pode não ser a solução ótima.

Usando termos da Tabela 4.1, cada indivíduo é considerado um “cromossomo” e, na representação clássica de algoritmos genéticos, ele é codificado como um vetor de caracteres, ou cadeia (*string*) de atributos, de tamanho fixo, formado pela concatenação dos caracteres “0” e “1” do alfabeto binário {0,1} (representação binária). Existem variações para esta codificação, como a representação em ponto flutuante, onde o vetor de tamanho fixo é formado pela concatenação de elementos que são números reais (MICHALEWICZ, 1996).

Um aspecto importante a ser considerado para o sucesso do processo evolutivo refere-se ao tamanho da população inicial e da população nas subseqüentes gerações, pois é possível comprometer a evolução dos indivíduos caso a quantidade escolhida seja inadequada. Este parâmetro, exceto em casos muito particulares, deve ser estabelecido empiricamente e de acordo com a disponibilidade de recursos computacionais (GOLDBERG, 1983; GOLDBERG, 1989; HOLLAND, 1992).

Uma outra etapa de grande impacto no desempenho do algoritmo genético é a fase de seleção de indivíduos para reprodução. Existem vários tipos de seleção que podem ser aplicados (GOLDBERG, 1989). Entre os mecanismos existentes, destaca-se a seleção pela Roleta (ou “Roulette Wheel”, na literatura em inglês) adotada em GOLDBERG (1983) e a seleção por torneio (DEJONG, 1975; BLICKLE, 2000). No caso da seleção por torneio, estudos comparativos entre este mecanismo e outros podem ser encontrados em KOZA (1992).

A forma de codificação adotada para representar cada indivíduo (ou cromossomo) irá influenciar na determinação dos operadores genéticos a serem aplicados e como serão utilizados os operadores escolhidos. Tais operadores possuem variações. O operador de crossover pode ser simples, multiponto, uniforme, ordenado, aritmético, ou uma combinação deles (GOLDBERG, 1989; MICHALEWICZ, 1996; BÄCK *et al.*, 2000a; BÄCK *et al.*, 2000b). O mesmo acontece com o operador de mutação, o qual possui variantes e todas dependem do tipo de codificação adotada para se definir o cromossomo, além de propriedades específicas do espaço de busca.

O mecanismo de mutação sempre opera sobre cromossomos individuais, alterando seu material genético. Ele pode atuar em apenas um gene de cada vez (mutação simples) ou em uma porcentagem de genes determinada aleatoriamente (mutação aleatória). No caso de uma codificação binária, esta mutação ou alteração do código genético corresponde simplesmente à troca de um bit pelo seu complemento. No caso de uma codificação em ponto flutuante, a mutação corresponde geralmente ao acréscimo de um valor, extraído de uma distribuição aleatória, ao gene escolhido (ou aos genes escolhidos).

Para representação em ponto flutuante, destacamos dois tipos de mutação: mutação uniforme, onde o valor aleatório a ser acrescido ao gene (ou genes) provém de uma distribuição constante ao longo do processo evolutivo; e mutação não-uniforme, onde o valor a ser acrescido provém de uma distribuição que depende do tempo decorrido ao longo do processo evolutivo (MICHALEWICZ, 1996).

Os algoritmos genéticos podem ser empregados em conjunto com outras técnicas

artificiais para modelar SCD, dotando-as deste modo de aspectos evolutivos essenciais a seu desempenho. Expõe-se na próxima seção uma dessas composições, também proposta por HOLLAND (1986; 1992), a qual uniu o algoritmo genético a outra ferramenta computacional: os *sistemas classificadores*. No final da seção, apresenta-se um exemplo didático contendo alguns passos da aplicação dos AG e sistemas classificadores a um problema específico.

#### **4.4.2 Sistemas Classificadores com Aprendizado**

Um sistema classificador com aprendizado (ou *Learning Classifier Systems* (LCS), na literatura em inglês) constitui uma estratégia de computação evolutiva para criar e atualizar regras (chamadas classificadores), as quais são capazes de governar a ação de agentes adaptativos de forma eficiente em ambientes dinâmicos (BOOKER *et al.*, 1989; HOLLAND, 1992).

Esta denominação de classificador para as regras pode conduzir a uma interpretação equivocada visto que o papel das regras nem sempre está voltado para classificar situações ou eventos. Mais recentemente, o próprio autor incluiu os sistemas classificadores com aprendizado em um contexto mais amplo formado pelos sistemas complexos adaptativos (HOLLAND, 1995). No entanto, iremos manter a denominação de classificadores para as regras, coerente com iniciativas similares na literatura.

Existe um grande número de variantes do modelo original proposto por HOLLAND (1986). Esta seção descreve o sistema classificador original e apresenta uma revisão dos outros modelos mais conhecidos até o momento.

##### **4.4.2.1. O Sistema Classificador de John Holland**

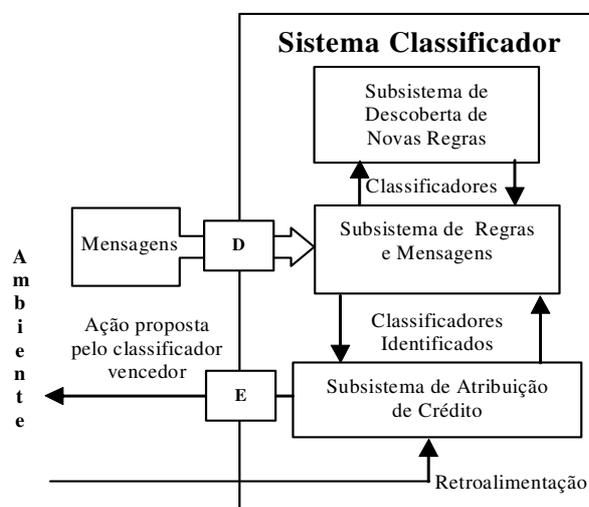
O conceito de sistemas classificadores foi originalmente proposto por HOLLAND (1986; 1992). Trata-se de uma abordagem que se inspira nas teorias evolutivas e nos processos da natureza para solução de problemas. Daí segue a sugestão de classificação

circunstancial desta ferramenta como um sistema: complexo, organizado, artificial, bio-inspirado, de inteligência computacional e evolutivo (Capítulo 2, Seção 2.3). Esta técnica foi criada com o objetivo específico de simular agentes de um sistema complexo.

Existem alguns conceitos básicos relacionados aos SC:

- 1) os classificadores, ou regras, são compostos por uma parte antecedente e outra conseqüente (existem variações em que um classificador pode possuir duas ou mais condições na parte antecedente). A parte antecedente do sistema classificador é um vetor de tamanho fixo, formado pela concatenação dos caracteres “0”, “1” e “#”, os quais são elementos do conjunto que compõe o alfabeto ternário {0,1,#}. O caractere “#”, conhecido como o símbolo “*don’t care*”, tem uma função análoga à exercida por um curinga em um jogo de cartas, podendo assumir o valor “0” ou “1”. A parte conseqüente é um outro vetor de tamanho fixo, formado pela concatenação dos caracteres “0” e “1” do alfabeto binário {0,1}.
- 2) o sistema classificador comunica-se com o ambiente externo através de “detectores” de mensagens e de “executores”. Os detectores são responsáveis pela recepção e codificação da mensagem (ou mensagens) recebida pelo sistema, transformando-as em uma linguagem inteligível ao sistema classificador. Os “executores” decodificam as ações propostas pelo sistema, para que as mesmas possam ser colocadas em prática.
- 3) as conseqüências encadeadas a partir de cada ação (etapa de retroalimentação ou *feedback*) determinam a “recompensa” adequada aos classificadores responsáveis pela ação.
- 4) a “energia” (ou *strength*, na literatura em inglês) associada a cada classificador é utilizada para expressar o vigor, ou força, de cada um durante o processo adaptativo.
- 5) a “especificidade” de cada classificador é uma medida inversamente proporcional à quantidade de símbolos “#” (*don’t care*) na parte antecedente do classificador.

Os SC dividem-se em três subsistemas distintos e interativos: o Subsistema de Regras e Mensagens, o Subsistema de Atribuição de Crédito e o Subsistema de Descoberta de Novas Regras (Figura 4.1).



**Figura 4.1 – Esquema simplificado de um sistema classificador, suas divisões internas e sua interação com o ambiente (D – detectores, E – executores).**

O Subsistema de Regras e Mensagens recebe as mensagens provenientes dos detectores e codifica-as, de forma que o sistema classificador possa reconhecê-las e colocá-las à disposição para um processo de identificação, o qual denomina-se “comparação” (ou *matching*, na literatura em inglês). Nesta fase de comparação, todos os classificadores tentam identificar sua parte antecedente com a mensagem.

Os classificadores que possuem todas as posições não conflitantes com as da mensagem (mesmo bit ou então “#”) serão escolhidos como os classificadores identificados para participarem de uma “competição” no Subsistema de Atribuição de Crédito. Se não houver nenhum classificador que atenda a esta condição, uma alternativa é a utilização da medida de distância de Hamming e escolher o classificador com menor distância à mensagem. Ou ainda pode-se criar um novo classificador que se identifica com esta mensagem (RICHARDS, 1995).

A competição caracteriza-se por uma forma de avaliação dos classificadores, sendo que os mais bem adaptados disputarão o direito de atuar sobre o ambiente. O ganhador da competição será o classificador que apresentar maior lance efetivo (ou *effective bid*, na literatura em inglês).

A Equação 4.1 apresenta a fórmula geral do cálculo da nova energia do classificador a cada iteração (VARGAS, 2000), reproduzindo todo o efeito do mecanismo envolvido no processo de tomada de decisão sobre cada classificador.

É oportuno ressaltar que o lance efetivo empregado durante a competição é caracterizado pela presença de um ruído gaussiano, o qual é aplicado ao  $Bid_t$  (Equação 4.1). Este ruído garante um grau de aleatoriedade durante o processo de competição.

Após a competição, o classificador ganhador atuará sobre o ambiente e receberá uma recompensa ou punição. A função do Subsistema de Atribuição de Crédito é definir o valor de  $R_t$  (Equação 4.1) e incorporar este valor à energia do classificador ativo no momento, ou a um elenco de classificadores que atuou recentemente sobre o ambiente.

$$S_{t+1} = (1 - Taxa\_v) * S_t + R_t - Bid_t - Taxa\_bid \quad \text{Equação 4.1}$$

onde :

- $Taxa\_v$  : taxa de vida
- $S_t$  : energia ou “*strength*” no instante  $t$
- $R_t$  : valor com base na retroalimentação dada pelo ambiente, caso o classificador tenha sido vencedor da competição no instante  $t-1$  (♦)
- $Bid_t$  : lance do classificador no instante  $t$ , pago somente se o classificador foi vitorioso na competição no instante  $t-1$
- $Taxa\_bid$  : taxa de participação na competição

(♦)  $R_t > 0$  , em caso de recompensa (ação positiva) e  $R_t < 0$  em caso de punição (ação negativa)

O classificador vencedor será responsável pela ação sobre o ambiente. O ambiente, por sua vez, fornece uma nova mensagem caracterizando seu novo estado (retroalimentação), o qual será o ponto de partida para se definir o valor da recompensa  $R_t$ . Em lugar do ambiente fornecer seu novo estado como ilustrado na Figura 4.1, é possível que os próprios detectores de

mensagens forneçam tal informação. Em seguida, volta-se novamente ao tratamento de mensagens e atribuição de crédito. O processo continua por uma “época” de iterações. Ao final de cada época, o sistema classificador participará de outra fase do processo evolutivo, a fase de descoberta de novas regras, onde então se aplicam os procedimentos intrínsecos aos algoritmos genéticos (Seção 4.4.1).

Basicamente, o algoritmo genético produz uma nova geração de classificadores pela aplicação em uma parte da população original dos operadores de seleção, crossover e mutação. A probabilidade de seleção de um classificador é proporcional à sua energia. Os filhos gerados serão inseridos na população em substituição aos indivíduos com menor energia.

Existem duas variantes para formação dos classificadores: a abordagem “Pittsburgh”, na qual um indivíduo representa a solução para o problema; e a abordagem “Michigan”, na qual a solução é dada pela população e não pelos indivíduos da população. Portanto, no caso da abordagem “Michigan”, existe uma única solução sendo evoluída (MICHALEWICZ, 1996) e no caso da abordagem “Pittsburgh”, existem várias propostas de solução sendo evoluídas ao mesmo tempo.

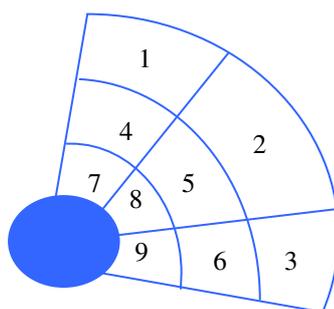
Usualmente, pode-se empregar *tags* na composição das mensagens e do corpo dos classificadores. As *tags* são implementadas de forma a separar uma parte da mensagem (prefixo ou sufixo) para especificar um determinado contexto do ambiente e conseqüentemente limitar quais classificadores da população irão se identificar com esta mensagem específica. O uso de *tags* em sistemas classificadores contribui para a introdução de modularidade no processamento das mensagens. HOLLAND (1990) defende o emprego de *tags* em sistemas classificadores, mencionando que as *tags* constituem “blocos construtivos” naturais para modelos emergentes em sistemas classificadores: “Tags fornecem a ‘cola’ para modelos em sistemas classificadores”, p.194 (“blocos construtivos” são conjuntos de classificadores que possuem informações relevantes em sua composição, os quais podem ser selecionados durante a aplicação do algoritmo genético para criar potenciais classificadores na próxima geração). Resumindo, *tags* promovem associações dependentes de contexto, i.e. uma mensagem com determinada *tag* que define um contexto pode ativar um conjunto específico de classificadores que a identificam

gerando modelos emergentes. O sistema classificador que compõe o sistema híbrido a ser discutido no Capítulo 5 emprega *tags* em sua composição.

Descreve-se a seguir parte de um exemplo didático particular apresentado em VARGAS (2000), destacando-se para efeito desta tese somente a codificação da população de classificadores do sistema classificador e a aplicação do algoritmo genético. O modelo escolhido foi o de navegação autônoma de um agente em um ambiente a ser explorado.

#### 4.4.2.2. Exemplo Didático: Aplicação de um Sistema Classificador com Aprendizado para Desvio de Obstáculos em Navegação Autônoma

O exemplo didático a ser esboçado trata do controle da navegação de um agente autônomo em um ambiente ainda inexplorado. O agente, esquematizado na Figura 4.2, sob a forma de um círculo com nove campos sensoriais, utilizará um sistema classificador para governar a tomada de decisão frente a situações diversas presentes em seu cenário de navegação.



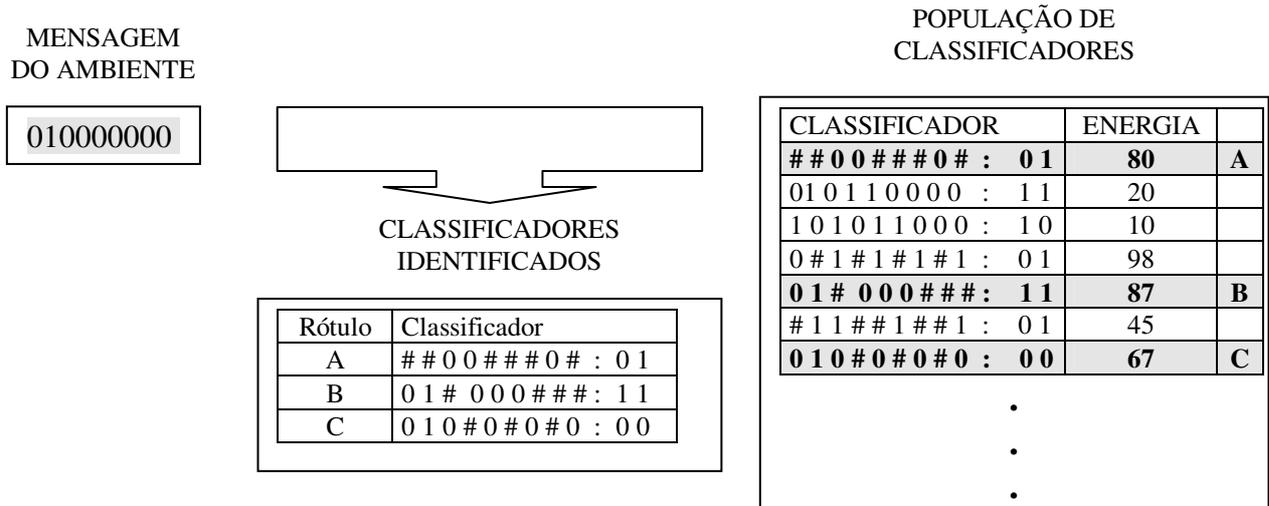
**Figura 4.2 – O agente e seus campos sensoriais.**

A seguir, serão evidenciados apenas alguns aspectos da formulação e da funcionalidade dos módulos que compõem o sistema classificador.

*Codificação da População de Classificadores*

Cada classificador é representado por uma regra, constituída por um vetor de onze posições. As nove primeiras posições refletem os nove campos sensoriais do sensor de visão do agente (chamada “parte antecedente”). A 10ª e a 11ª posições representam a ação a ser tomada (“parte conseqüente”); “00” e “11” significam siga em frente, “01” significa vire 15° à direita, e “10” significa vire 15° à esquerda.

Observa-se na Figura 4.3 a codificação de uma mensagem do ambiente e da população de classificadores ilustrando o processo de identificação desta mensagem. Neste processo de codificação da mensagem, o estado detectado pelos campos sensoriais foi transformado em uma seqüência de bits 010000000, indicando a existência de um obstáculo no campo 2 (Figura 4.2).



**Figura 4.3 – Exemplo de codificação da mensagem do ambiente e da população de classificadores ilustrando o processo de identificação da mensagem.**

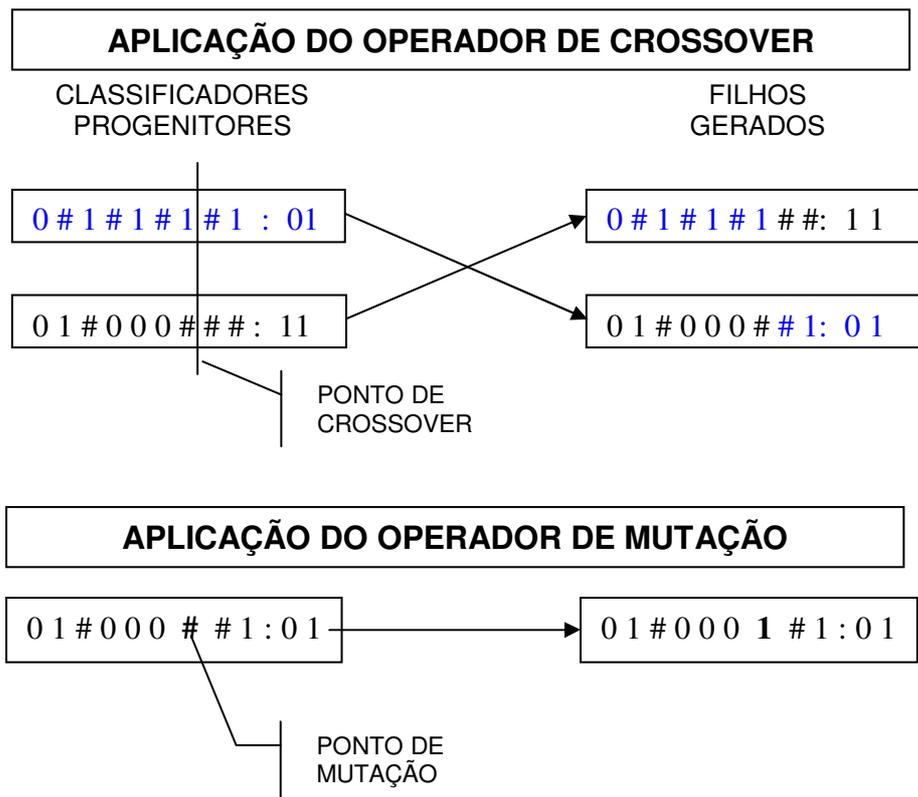
Para esta mensagem do ambiente, foram seleccionados 3 classificadores (arbitrariamente rotulados como **A**, **B** e **C**), os quais sugerem como próxima ação <vire 15° à direita> (01) e <siga em frente> (11 e 00).

Apenas um desses três classificadores irá vencer o processo competitivo, sendo que o valor atual de energia dos classificadores identificados (A:80, B:87 e C:67) irá influir no processo de competição (VARGAS, 2000).

*Aplicação do Algoritmo Genético*

Após o processo de seleção dos classificadores, seguem-se três fases: a primeira é a de competição entre os classificadores selecionados, a segunda de atuação sobre o ambiente e a terceira de recompensa ou punição. Maiores detalhes sobre essas três fases podem ser encontrados em VARGAS (2000), sendo que será tratada aqui apenas a fase subsequente: aplicação de um algoritmo genético sobre a população de classificadores.

A Figura 4.4 ilustra a aplicação dos operadores de crossover e mutação do algoritmo genético em dois indivíduos da população de classificadores e em um indivíduo, respectivamente. O ponto de crossover foi selecionado aleatoriamente logo após o locus de número oito. Para mutação foi escolhido aleatoriamente o gene do locus número sete e como se trata do símbolo “#”, este poderá ser alterado para “0” ou “1”.



**Figura 4.4 – Exemplo de aplicação dos operadores de crossover e mutação do algoritmo genético, vinculado ao Subsistema de Descoberta de Novas Regras.**

A fase de aplicação do algoritmo genético caracteriza a descoberta de novas regras. Uma vez definida a nova população de classificadores, segue-se mais uma “época” de iterações do processo de navegação. Observa-se que na união dos dois paradigmas de computação evolutiva existem duas fases distintas, uma de operação e outra de evolução. Na primeira, ajusta-se a energia dos classificadores e, na segunda, utiliza-se esses valores ajustados como parâmetro para o processo evolutivo.

O exemplo didático apresentado ilustra os procedimentos inerentes ao sistema classificador original. A próxima seção enumera os modelos alternativos ao arquétipo proposto por John Holland, juntamente com um breve histórico de desenvolvimento deste campo particular de pesquisa.

#### 4.4.2.3. Outros Modelos de Sistemas Classificadores

O sistema classificador descrito até o momento corresponde ao modelo original proposto por HOLLAND (1992). Entretanto existe um número de variantes do modelo original (LANZI *et al.*, 2000; LANZI *et al.*, 2001), como pode ser observado na Tabela 4.2.

**Tabela 4.2 – Principais modelos de sistemas classificadores (adaptado de KOVACS (2000)).**

Ano	Tipo	Nome	Autor
1975	CS	Classifier System	John Holland (HOLLAND, 1992)
1986	LCS	Learning CS	John Holland (HOLLAND, 1986)
1985	CSM	CS with Memory	Hayong Harry Zhou (ZHOU, 1985)
1989	HCS	Hierarchical	Lingyan Shu & Jonathan Schaeffer (SHU & SCHAEFFER, 1989)
1989	SCS	Simple CS	David Goldberg (GOLDBERG, 1989)
1989	VCS	Variable CS	Lingyan Shu & Jonathan Schaeffer (SHU & SCHAEFFER, 1989)
1990	PCS	Predictive CS	Piet Spiessens (Spiessens, 1990 em KOVACS & LANZI, 1999)
1994	FCS	Fuzzy Classifier System	Takeshi Furuhashi, Ken Nakaoka & Yoshiki Uchikawa (FURUHASHI <i>et al.</i> , 1994).

Ano	Tipo	Nome	Autor
1994	ZCS	Zeroth-level CS	Stewart W. Wilson (WILSON, 1994)
1995	OCS	Organizational Classifier System	Jason Wilcox (WILCOX, 1995) e Takadama e colaboradores (TAKADAMA <i>et al.</i> , 1999)
1995	XCS	Special Classifier System	Stewart W. Wilson (WILSON, 1995)
1996	ACS	Anticipatory CS	Wolfgang Stolzmann (STOLZMANN, 1996)
1997	EpiCS	Inspirado em NEWBOOLE (Bonelli et al., 1990)	John H. Holmes (HOLMES, 1997)
1999	CCS	Corporate CS	Andy Tomlinson & Larry Bull (TOMLINSON & BULL, 1999)

Entre os modelos da Tabela 4.2, destacam-se o **XCS** criado por Wilson em 1995 (WILSON, 1995) e o **ACS** proposto por Stolzmann em 1996 (STOLZMANN, 1996). Estes dois modelos distinguem-se pela aceitação da comunidade científica em termos de extensões e trabalhos publicados, e pelos bons resultados obtidos em aplicações que vão desde a mineração de dados até robótica móvel. Ressaltam-se, a seguir, as principais diferenças do XCS e do ACS em relação ao modelo clássico de Holland.

### 1) XCS

No XCS ou *Special Classifier System*, na literatura em inglês, a energia de cada classificador é substituído por três parâmetros: predição, erro de predição e *fitness*. Cada classificador mantém uma predição do pagamento esperado por sua ação no ambiente e esta predição é uma média do pagamento recebido. O erro de predição, por sua vez, é uma média do valor do erro no parâmetro de predição.

O algoritmo genético é aplicado em nichos definidos de acordo com o grau de similaridade com a mensagem do ambiente, e não mais aleatoriamente. O *fitness* de cada classificador é um número calculado por uma função inversa do erro médio de predição, ou seja,

o *fitness* baseia-se na medida de quão precisa é uma predição. Forma-se, dessa maneira, um vetor de predições para cada ação.

A recompensa é somada a um valor calculado com base na maior predição do vetor de predições -  $P$ . Em seguida, atualiza-se o valor da predição  $p$  de cada classificador com base neste novo valor de recompensa. O *fitness* é recalculado utilizando o valor atual do erro. O erro é ajustado utilizando como base o valor  $P$  e o novo valor de  $p$ . Maiores detalhes acerca do equacionamento podem ser encontrados em WILSON (1995).

## 2) ACS

No ACS ou *Anticipatory Classifier System*, na literatura em inglês, existe um controle antecipado do comportamento do classificador. Este controle permite que se crie um modelo interno do ambiente.

A principal diferença do ACS para os outros sistemas classificadores reside no fato do módulo de Descoberta de Novas Regras estar integrado ao módulo de Atribuição de Crédito. Neste caso, o algoritmo de descoberta de novas regras utiliza as informações enviadas pelo ambiente em tempo real, criando novos classificadores por demanda. Dessa forma, evita-se que “blocos construtivos” de classificadores sejam destruídos quando da aplicação do algoritmo genético.

### 4.4.2.4. Desafios e Perspectivas para os Sistemas Classificadores com Aprendizado

Apesar da existência de um número de variantes do modelo original, ainda existem muitos desafios a serem enfrentados na área de sistemas classificadores. É possível enumerar três principais aspectos ainda não devidamente explorados. São eles:

**Generalização.** Habilidade de um sistema em representar de forma compacta o que foi aprendido e aplicar esta aprendizagem a novas situações. De acordo com Holmes e colaboradores (HOLMES *et al.*, 2000), a observação deste aspecto expõe várias questões: O que governa a evolução de classificadores especialistas e totalmente genéricos? Quais são as especificações do sistema que levam a uma generalização efetiva? Quais são as classes mais difíceis de problemas? Devemos investigar formas alternativas de implementar generalização, ou os algoritmos genéticos são a melhor opção?

**Escalabilidade.** Refere-se à rapidez do tempo de aprendizado de um sistema ou de seu desenvolvimento, frente a um aumento de complexidade do problema. Como o aspecto de generalização é altamente correlacionado com o aspecto escalabilidade, pressupõe-se que um sistema capaz de generalizar de forma apropriada seja capaz de aprender tarefas complexas rapidamente e com menos recursos de processamento e memória.

**Antecipação.** A habilidade de um sistema prever ou antecipar o resultado de suas ações levantou uma questão adicional (HOLMES *et al.*, 2000): além dos modelos atuais com base no modelo de STOLZMANN (1996), existem outras abordagens capazes de acrescentar antecipação aos SC?

De acordo com HOLMES *et al.* (2000), esses três desafios fazem parte de uma gama de caminhos e novas fronteiras ainda inexploradas no campo de SC. Vargas e colaboradores (VARGAS *et al.*, 2002) em um estudo recente, apresentaram alternativas a estas dificuldades através da identificação de características complementares entre o sistema classificador clássico e os sistemas imunológicos artificiais. Os autores trataram conceitualmente e exploraram preliminarmente a aplicação de propriedades e metodologias encontradas em sistemas imunológicos artificiais na solução destes problemas de generalização, escalabilidade e antecipação.

Apesar da existência dessas lacunas a serem preenchidas, com base em estudos anteriores pode-se ressaltar que o modelo original de sistemas classificadores apresenta um comportamento típico de um sistema complexo adaptativo (SCD), onde a exposição repetida a um dado estado do ambiente produz uma resposta de melhor qualidade.

Desta forma, pode-se afirmar que, apesar dos obstáculos a serem vencidos, o sistema classificador clássico e suas extensões são suficientemente flexíveis para se adaptarem a novos contextos nunca antes apresentados. Além disso, o sistema classificador clássico já se mostrou eficaz na produção de respostas secundárias a estímulos recorrentes do ambiente devido à sua capacidade de manter o nível de diversidade da população (VARGAS *et al.*, 2004). Esta memorização de regras bem-sucedidas num passado não muito longínquo, permite que as mesmas possam voltar a atuar prontamente, caso se repitam condições ambientais já experimentadas.

Acredita-se que um aspecto relevante, e ainda não mencionado nos desafios enumerados até então, está relacionado à falta de qualquer *interação* direta das regras ou classificadores na ausência do “Bucket Brigade”<sup>‡</sup>. Uma das propostas desta tese está em dotar o sistema classificador clássico de poder de interação e comunicação entre as regras, instituindo-se uma coerência entre ações passadas, presentes e futuras. Deste modo, como será explicitado no Capítulo 5, sugere-se a criação de uma *rede de classificadores* conectados através de processos evolutivos e dinâmicos. Com isso, acredita-se que os classificadores que até o momento somente *competiam* entre si, passem também a praticar a *cooperação*, dinamicamente, com efeitos diretos em comportamento antecipatório e na sintonia fina da energia ou valor relativo de cada classificador.

---

<sup>‡</sup>O termo “Bucket Brigade” foi cunhado por HOLLAND (1992) para designar uma tentativa de se criar um canal de comunicação entre os classificadores. Ele escolheu este termo fazendo analogia à ação de uma brigada (“brigade”) de incêndio, onde baldes (“buckets”) de água são carregados passando-os de mãos em mãos em uma fila única.

## 5. UMA ABORDAGEM UNIFICADA PARA SISTEMAS COMPUTACIONAIS BIO-INSPIRADOS

5.	UMA ABORDAGEM UNIFICADA PARA SISTEMAS COMPUTACIONAIS BIO-INSPIRADOS ...	81
5.1.	CLARINet: Uma Rede Imunológica de Classificadores.....	82
5.1.1	Fundamentos.....	83
5.1.2	Especificação do Modelo.....	84
5.1.3	Dinâmica da Rede.....	86
5.1.4	Algoritmo Resumido.....	90
5.2.	Caso de Estudo: Robótica Autônoma.....	91
5.2.1	Robótica Autônoma: Um Desafio Cognitivo.....	92
5.2.2	Descrição do Problema.....	93
5.2.3	Um Cenário para Simulação.....	94
5.2.4	Modelagem do Problema.....	97
5.2.4.1.	Codificação das Mensagens (Antígenos).....	97
5.2.4.2.	Codificação dos Classificadores (Anticorpos).....	98
5.2.4.3.	Exemplo de Codificação das Mensagens e dos Classificadores.....	98
5.2.5	Evolução e Aprendizado da Rede Imunológica de Classificadores.....	101
5.2.6	Resultados Preliminares.....	103
5.2.7	Análise do Experimento e Resultados.....	105

Os capítulos 5 e 6 tratam da síntese e aplicação de sistemas computacionais bio-inspirados, empregando conceitos abordados nos capítulos anteriores. Portanto, cabe aqui motivar e distinguir apropriadamente estes dois capítulos.

O capítulo 5 apresenta uma abordagem unificada com base nos conceitos de sistemas híbridos, conforme introduzidos no Capítulo 1, incluindo sistemas de inteligência computacional e sistemas homeostáticos artificiais. Faz-se isso através da união de dois paradigmas computacionais: os sistemas classificadores e os sistemas imunológicos artificiais. Já o capítulo 6 apresenta uma abordagem integrada de um sistema homeostático artificial envolvendo redes neurais artificiais e um novo modelo de sistema endócrino artificial.

Com o intuito de verificar a validade e mensurar alguns aspectos da potencialidade das ferramentas propostas, faz-se uso da robótica autônoma como caso de estudo, sendo que no capítulo 5 recorre-se apenas a experimentos simulados computacionalmente, enquanto que no capítulo 6 são incluídos resultados com um robô real.

Ao investigar a união de abordagens conexionistas, o presente trabalho recorre à linha de raciocínio de FARMER (1990), segundo a qual abordagens unificadas e com forte característica conexionista podem simplificar a modelagem de um processo elaborado e desafiador como o controle autônomo de robôs. No entanto, as vantagens e desvantagens relativas das novas propostas desta tese frente a abordagens alternativas existentes na literatura, assim como a adoção de procedimentos que possibilitem uma comparação direta entre as propostas dos capítulos 5 e 6, ficam como perspectiva futura da pesquisa, o que será devidamente justificado no capítulo 7.

### **5.1. CLARINet: Uma Rede Imunológica de Classificadores**

A idéia de uma concepção híbrida, contemplando a união de dois paradigmas computacionais, os sistemas classificadores com aprendizado (SC) e os sistemas imunológicos artificiais (SIA), partiu da observação de trabalhos na literatura, onde estas duas ferramentas foram comparadas por vários autores e de formas distintas, evidenciando-se as suas diferenças e semelhanças. O primeiro trabalho a investigar os dois sistemas de forma comparativa foi escrito por Farmer e colaboradores (FARMER *et al.*, 1986). Ele é considerado um trabalho pioneiro na área de sistemas imunológicos artificiais (DE CASTRO & TIMMIS, 2002).

Com exceção de GASPAR & HIRSBRUNNER (2002), todos os trabalhos até então foram desenvolvidos considerando-se cenários específicos e, em sua maioria, concentrados nos aspectos filosóficos e comparativos dos dois sistemas. GASPAR & HIRSBRUNNER (2002) foram os primeiros a fazerem uma tentativa de união dos dois sistemas, combinando um algoritmo imunológico, chamado de YaSais, o qual agrega conceitos de seleção clonal e alguns conceitos relacionados à existência de memória no sistema imunológico (Capítulo 3, Seção 3.2.3), com uma variante do modelo original de SC, a abordagem Pittsburgh (Capítulo 4, Seção 4.4.2.1). Os autores propuseram um sistema híbrido denominado PICS (do inglês “*Pittsburgh Immune Classifier System*”). O sistema foi avaliado em experimentos simples que simulavam ambientes estáticos e dinâmicos. Os resultados preliminares revelaram a capacidade de resposta secundária

do sistema, a qual já havia sido identificada em um trabalho anterior empregando somente um modelo de sistema classificador padrão (VARGAS, 2000; VARGAS *et al.*, 2002; VARGAS *et al.*, 2004). A resposta secundária refere-se à qualidade da resposta do sistema que se aprimora cada vez que o sistema se depara com uma situação já vivenciada anteriormente. Apesar do aspecto simplista da experimentação adotada e da natureza apenas confirmatória dos resultados apresentados, este primeiro ensaio de GASPAR & HIRSBRUNNER (2002) demonstrou que a combinação dos SIA e dos SC pode resultar em um sistema robusto e flexível.

A proposta deste capítulo difere conceitualmente do modelo proposto em GASPAR & HIRSBRUNNER (2002) em vários aspectos. Primeiro, emprega-se a abordagem Michigan em SC, de modo que o processo evolutivo vai considerar a evolução de um único conjunto de classificadores (ou regras). Sendo assim, em lugar de considerar uma população de conjuntos de classificadores, opera-se com um único conjunto que constitui uma solução para o problema a ser tratado. Desta forma, reduz-se consideravelmente o custo computacional e simplifica-se o processo evolutivo. Repare que a abordagem continua sendo baseada em população, mas agora os indivíduos são classificadores isolados, e não um conjunto de classificadores. Segundo, trata-se de um sistema híbrido que promove a interação dos classificadores na forma de uma rede imunológica artificial. A rede imunológica é inspirada na teoria das redes idiotípicas de JERNE (1974), empregando equações diferenciais derivadas do modelo proposto por Farmer e colaboradores (FARMER *et al.*, 1986). Terceiro, com a nova concepção de sistemas classificadores em rede, a etapa evolutiva dos sistemas classificadores não mais se restringe às células e se estende às conexões da rede imunológica.

### **5.1.1 Fundamentos**

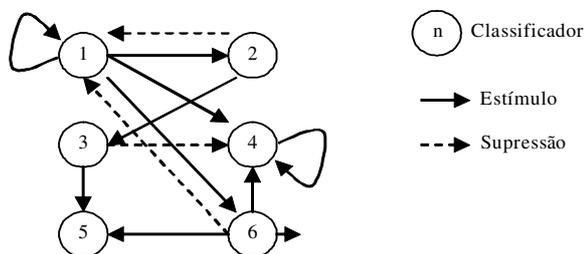
A proposta de uma rede imunológica de classificadores, denominada CLARINet (do inglês “CLAssifieR Immune Network”), procura combinar algumas das melhores características dos SC juntamente com propriedades adaptativas e mecanismos de regulação dos SIA, neste último, em particular as relacionadas com a teoria da rede imunológica. Os SC possuem a habilidade de ajustar suas regras, ou classificadores, dinamicamente, através da evolução de um

conjunto de regras capazes de guiar as ações de um agente adaptativo em um cenário dinâmico. Entretanto, é sabido que as interações das regras em um sistema classificador padrão são normalmente fracas, ou seja, existe muita competição e pouca cooperação (FARMER, 1990). Já os modelos computacionais de redes imunológicas empregam agentes que emulam células e moléculas com estruturas predefinidas e se baseiam nas conexões da rede para definir a dinâmica das interações através das concentrações de seus elementos, sendo que cada elemento representa uma célula da rede imunológica. Desta forma, pode-se argumentar que esta proposta de hibridização procura fundamentar-se na teoria da cooperação, articulada por AXELROD (1984), a qual ressalta a relevância da modelagem das interações para que ocorra a emergência de um comportamento cooperativo ao longo da evolução.

A CLARINet, a ser introduzida neste capítulo, explora conjuntamente esses dois paradigmas em busca de um sistema híbrido que procure ao mesmo tempo manter a natureza adaptativa dos elementos constituintes do sistema classificador e implementar um processo interativo intenso entre esses elementos, formando efetivamente uma rede de classificadores, ou seja, uma rede imunológica com células e conexões adaptativas. Neste sentido, a CLARINet vai expressar múltiplos processos auto-organizados e dinâmicas não-lineares acopladas, com os estímulos externos promovendo *perturbações* que podem inclusive conduzir a mudanças de ponto de operação ou alterações qualitativas no comportamento dinâmico do sistema.

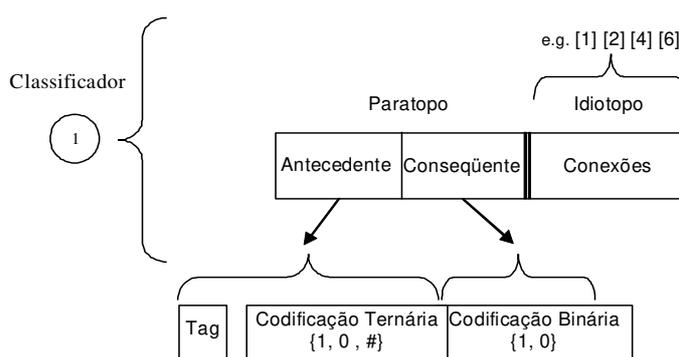
### **5.1.2 Especificação do Modelo**

Como existe uma equivalência entre os anticorpos (em um modelo de rede imunológica) e os classificadores (em um sistema classificador) (VARGAS *et al.*, 2002), propõe-se uma “rede imunológica de classificadores” onde cada célula da rede corresponde a um classificador, o mesmo que é definido em um sistema classificador convencional (Capítulo 4, Seção 4.4.2.1). A estrutura é ilustrada na Figura 5.1. Recorda-se do Capítulo 3, Seção 3.2.3.1, que quando um anticorpo reconhece um antígeno ou outro anticorpo, ele é estimulado e, caso o anticorpo seja reconhecido por outro anticorpo, através de seu idiotopo, ele sofre supressão.



**Figura 5.1 – Exemplo de uma rede imunológica de classificadores. Seta em linha cheia indica estímulo que uma célula está recebendo e seta tracejada indica supressão (nem todas as conexões possíveis estão ilustradas).**

Esta equivalência entre anticorpos e classificadores permite que sejam considerados ao mesmo tempo a energia (normalmente atribuída aos classificadores e também denotada por *strength*) e o nível de concentração (normalmente atribuído aos anticorpos) das células da rede, aspecto a ser explorado na Seção 5.1.3. Nesta estrutura básica, as células que compõem a rede possuem duas partes principais: o paratopo, que corresponde a um classificador (ou regra) e, o idiotopo, que indica a quais outros classificadores o classificador em questão está conectado (Figura 5.2).



**Figura 5.2 - Estrutura de uma célula ou classificador em uma rede imunológica de classificadores. Esta estrutura é equivalente a de um anticorpo em uma rede imunológica, incluindo seu paratopo e idiotopo. A parte antecedente é subdividida em duas partes: “tag” e condição.**

O paratopo do classificador é dividido em parte antecedente e parte conseqüente. A parte antecedente, por sua vez, é subdividida em duas partes, *tag* e *condição*. Como já mencionado no Capítulo 4, Seção 4.4.2.1, a *tag* funciona como um identificador, restringindo o classificador a identificar somente mensagens com a mesma *tag*. A *condição* é codificada como um vetor formado pelo alfabeto ternário {1, 0, #}. A parte conseqüente do classificador, ou *ação*, é codificada como um vetor binário.

As conexões, ou idiotopo do classificador, indicam a quais outros classificadores ele está conectado. Por exemplo, na Figura 5.2 o classificador esquematizado corresponde à célula número 1 da Figura 5.1 e, de acordo com seu idiotopo, ele está conectado com ele mesmo e com os classificadores de índice 2, 4 e 6.

A seguir, descreve-se o modelo da CLARINet enfatizando-se a dinâmica da rede, ou seja, como os seus componentes básicos, os classificadores, interagem e se adaptam ao ambiente.

### 5.1.3 Dinâmica da Rede

Como mencionado anteriormente, o sistema híbrido desenvolvido classifica-se como do tipo incorporado, onde não é possível distinguir-se um subsistema do outro. Por conseguinte, ao descrever-se a dinâmica da rede imunológica de classificadores, observar-se-á que os mecanismos originais de um paradigma fundem-se com os mecanismos do outro.

A dinâmica da rede imunológica de classificadores segue o modelo proposto por Farmer e colaboradores (FARMER *et al.*, 1986), que é baseado na teoria original da rede imunológica de JERNE (1974). Deste modo, ela consiste nas interações mútuas de suas células imunológicas (neste caso, os classificadores). Como nos SC, estas interações iniciam-se a partir das mensagens recebidas do ambiente. Para a CLARINet, essas mensagens de entrada correspondem aos antígenos. O classificador que melhor se identificar com o(s) antígeno(s) ou mensagem(ns) proveniente(s) do ambiente irá proceder como um filtro, ou seja, seletivamente escolherá o antígeno que representa “a maior ameaça” ao sistema. Repare que, com esta formulação, a reação da rede imunológica não se dará ao antígeno diretamente. Este classificador, denominado

*antigênico*, irá postar uma mensagem na rede, na forma de sua parte antecedente. Esta mensagem será tratada pela CLARINet como um novo e único antígeno a ser combatido. Este antígeno irá *perturbar* a rede provocando uma variação no nível de concentração dos classificadores que o identificarem. Após a relaxação da dinâmica da rede, calcula-se o nível de ativação de todos os classificadores da rede e escolhe-se o de maior ativação. Esse classificador, denominado *ativado*, irá atuar sobre o ambiente através do emprego de sua parte conseqüente, ou ação.

O cálculo do nível de ativação do classificador dá-se pela multiplicação de sua *energia* por sua *concentração* e, portanto, permite o tratamento conjunto de duas variáveis que são originalmente tratadas em separado. A energia representa uma espécie de memória passada da efetividade de um classificador, enquanto que a *concentração* caracteriza-se como uma espécie de memória passada da efetividade de um anticorpo. Como na CLARINet há uma fusão do conceito de classificador com o conceito de um anticorpo, estas duas variáveis passam então a *cooperar* no sentido de determinar a melhor ação a ser tomada diante de um cenário apresentado pelo ambiente. Com a existência de duas variáveis associadas ao classificador, sua efetividade vai estar sujeita a um elenco mais rico de comportamentos temporais, se as condições de operação assim o exigirem.

Entre outras várias particularidades da CLARINet, deve-se explicitar o processamento interno da entrada de estímulos e saída de mensagens e a atribuição de crédito (ou procedimento de aprendizagem). Todos esses mecanismos citados no parágrafo anterior podem ser observados mais claramente na Figura 5.3, onde os mesmos foram divididos em duas fases: Fase 1 e Fase 2.

Recapitulando, na Fase 1 empregam-se os procedimentos intrínsecos ao sistema classificador padrão. Nesta fase, identifica-se o classificador *antigênico*. Na Fase 2, determina-se o nível de ativação dos classificadores, multiplicando-se sua *concentração* pela sua *energia*. Identifica-se, assim, o classificador com maior grau de ativação, denominado classificador *ativado*.

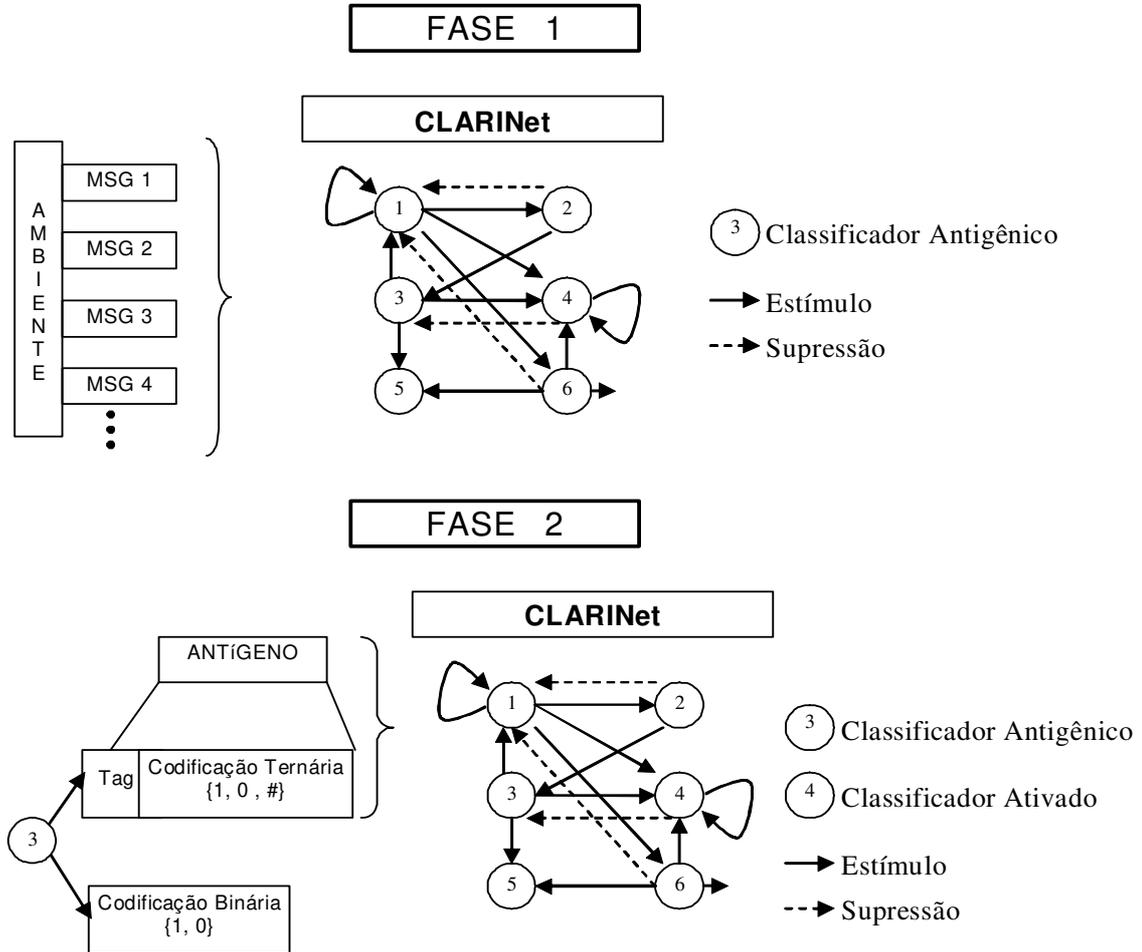


Figura 5.3 – Exemplo da Fase 1 e da Fase 2 do processamento interno da CLARINet.

Cada vez que o classificador *antigênico* estimula a rede através de sua parte antecedente, calcula-se a concentração de cada classificador empregando-se as Equações 3.1 e 3.2 do Capítulo 3, Seção 3.2.2.2. Recorda-se que este sistema de equações diferenciais acopladas que controla a rede imunológica deriva do modelo proposto por Farmer e colaboradores (FARMER *et al.*, 1986), e é rerepresentado a seguir:

$$\frac{da_i(t)}{dt} = \left( \alpha \sum_{j=1}^N m_{ji} a_j(t) - \beta \sum_{k=1}^N m_{ik} a_k(t) + \lambda m_i - k_i \right) a_i(t), \quad \text{Equação 5.1}$$

$$a_i(t) = \frac{1}{1 + \exp(0,5 - a_i(t))} \quad \text{Equação 5.2}$$

onde  $a_i(t)$  representa o nível de concentração do anticorpo  $i$ .

A Equação 5.2 é utilizada para limitar os valores das concentrações e, neste sistema, a concentração de um anticorpo varia no intervalo de 0 a 1. Da Equação 5.1, é importante

ressaltar que o termo  $\left\{ \alpha \sum_{j=1}^N m_{ji} a_j(t) \right\}$  representa o valor da soma das estimulações sofridas pelo

o anticorpo  $i$ , dados os anticorpos sobre os quais ele exerce supressão, e que o termo

$\left\{ \beta \sum_{k=1}^N m_{ik} a_k(t) \right\}$  representa o valor da soma das supressões sofridas pelo anticorpo  $i$ , dados os

anticorpos sobre os quais ele exerce estimulação. Os coeficientes  $\alpha$  e  $\beta$  indicam taxas de

estímulo e supressão. Repare que  $m_{ji}$  é nulo caso o anticorpo  $i$  não seja estimulado pelo

anticorpo  $j$ , da mesma forma que  $m_{ik}$  é nulo caso o anticorpo  $k$  não suprima o anticorpo  $i$ .

A estimulação do antígeno sobre o anticorpo  $i$  é representada pelo termo  $\lambda m_i$ , onde  $\lambda$  é a taxa com que a estimulação é exercida. O termo  $m_i$  é 1 caso o anticorpo esteja sofrendo estimulação antigênica, e 0 caso contrário. O termo  $k_i$  representa o coeficiente de morte natural de anticorpos do tipo  $i$ . Esse coeficiente faz com que a concentração dos anticorpos menos estimulados fique em níveis inferiores à dos demais.

No exemplo da Figura 5.3 (Fase 1 e Fase 2), o classificador de número 3 foi eleito o classificador *antigênico*, pois foi o que melhor se identificou com o(s) antígeno(s). Apesar deste fato, ele não pode atuar sobre o ambiente, porque a dinâmica da rede determinou que o classificador de número 4 deveria ser o classificador *ativado*.

Após a atuação no ambiente através da ação proposta pelo classificador *ativado*, o processo de atribuição de crédito incorpora um valor de reforço (recompensa ou punição), proporcional à retroalimentação do ambiente, a cada classificador envolvido direta ou indiretamente no processo de tomada de decisão. Desta forma, o valor de reforço é incorporado à energia do classificador *ativado*, do classificador *antigênico* e dos classificadores ligados

diretamente a eles via conexões da rede (idiotopos).

Todo o processo de aprendizagem, delineado acima, caracteriza um ciclo de operação e ajuste do sistema e corresponde a um ciclo de interação com o ambiente. A cada conjunto de ciclos de operação e ajuste (também denominado *época*), sobrevém a aplicação do processo evolutivo. Este procedimento ocorre através do emprego de um algoritmo genético junto à população de classificadores e conexões, e caracteriza um ciclo evolutivo do sistema.

Explicita-se, a seguir, o algoritmo resumido da rede imunológica de classificadores (CLARINet) com ênfase no ciclo de operação e ajuste do sistema (Fase 1 e Fase 2).

#### **5.1.4 Algoritmo Resumido**

A Figura 5.4 apresenta o algoritmo resumido da rede imunológica de classificadores, especificando as Fases 1 e 2 da dinâmica do sistema. Nota-se que, assim como os SC, a rede recebe as entradas através de detectores, promove ações, e recebe retroalimentação do ambiente. A estrutura da rede permite a aprendizagem por reforço (SUTTON & BARTO, 1998) não somente do classificador *ativado*, mas também de seus vizinhos definidos pelas conexões da rede, e do classificador *antigênico* (Passo 8, Figura 5.4).

**FASE 1**

**Passo 0 – Detectar** mensagens do ambiente.

**Passo 1 – Determinar** o classificador que melhor se identifica com o(s) antígeno(s)\*.

**FASE 2**

**Passo 2 – Apresentar** a parte antecedente deste classificador como um **antígeno** para a rede.

**Passo 3 – Aplicar** as equações de acoplamento dinâmico da rede para determinar o nível de concentração de cada classificador.

**Passo 4 – Multiplicar** a concentração de cada classificador pela sua respectiva medida de “*strength*” ou energia, determinando assim o nível efetivo de ativação de cada classificador.

**Passo 5 – Selecionar** o classificador com nível máximo de ativação.

**Passo 6 – Empregar** a ação determinada pela sua parte consequente

**Passo 7 – Receber** a retroalimentação do ambiente.

**Passo 8 – Reforçar** o classificador vencedor do Passo 1 e o classificador selecionado do Passo 5, juntamente com todos os classificadores que estão diretamente conectados a ele (ajuste do valor da energia).

**Passo 9 – Retornar** ao Passo 0.

\* neste ponto seguem-se os procedimentos de um sistema classificador padrão.

**Figura 5.4 – Algoritmo resumido da rede imunológica de classificadores (CLARINet).**

## **5.2. Caso de Estudo: Robótica Autônoma**

Com o intuito de se averiguar o desempenho da CLARINet, recorreu-se à robótica autônoma como caso de estudo. A escolha da navegação autônoma se deve ao fato de que o processamento da informação envolve tomada de decisão baseada em leituras sensoriais, as quais correspondem a sinais variantes no tempo e imprevisíveis, sob a hipótese de desconhecimento do ambiente de navegação. Além disso, de acordo com MICHELAN (2003), a síntese de controladores para navegação autônoma com base na operação de uma rede imunológica representa uma das iniciativas mais expressivas no sentido de explorar os aspectos cognitivos do sistema imunológico (DE CASTRO & TIMMIS, 2002; DE CASTRO, 2003). Sendo assim, também

segundo MICHELAN (2003), experimentos de navegação autônoma podem acabar contribuindo para a validação de conceitos e teorias da imunologia voltados para a cognição (VARGAS *et al.* 2003a).

### **5.2.1 Robótica Autônoma: Um Desafio Cognitivo**

No final da década de 1981-1990, o crescente interesse pelo estudo da inteligência levou ao surgimento de uma nova área de pesquisa denominada ciência cognitiva incorporada, ou “*embodied cognitive science*” na literatura em inglês, também conhecida como robótica baseada em comportamento. O novo termo fundamentou-se nas idéias de inteligência incorporada formuladas por BROOKS (1991a; 1991b). Para Brooks, a única forma de se entender a inteligência é fornecendo a ela um corpo, ou seja, somente transformando o objeto de estudo em um corpo material é possível ter acesso à interação do sistema com o mundo real, excluindo-se assim o papel do intérprete.

Contudo, essas idéias só foram totalmente assimiladas quando os pesquisadores começaram a utilizar robôs para estudar inteligência. De fato, a ciência cognitiva incorporada estabelece como sua principal metodologia o desenvolvimento de experimentos com agentes autônomos, isto é, robôs autônomos (PFEIFER & SCHEIER, 1999).

Existem várias maneiras de se conduzir experiências em robótica de forma sistemática. Entre essas, se destacam os experimentos simulados e os experimentos reais. Não obstante a discussão de vários cientistas em torno da eficácia de cada abordagem, para PFEIFER & SCHEIER (1999) ambas as propostas são válidas e a decisão dependerá somente do contexto no qual ela se insere.

Neste capítulo, emprega-se um agente robótico simulado utilizando o simulador desenvolvido por MICHELAN (2003). Visto que o autor já havia codificado uma rede imunológica como uma proposta de controle autônomo, a escolha deste simulador particular fundamentou-se exclusivamente na facilidade de implementação da nova proposta na plataforma já desenvolvida. É evidente que o módulo de controle autônomo não corresponde àquele proposto por

MICHELAN (2003), o qual está baseado na evolução das conexões de uma rede imunológica, tendo as células da rede sido definidas *a priori*. A CLARINet é então implementada e incorporada ao simulador na forma de um novo módulo de controle autônomo.

### 5.2.2 Descrição do Problema

Independente da controvérsia sobre a utilização de agentes robóticos reais ou simulados, para os propósitos deste capítulo, optou-se pelo ambiente de simulação. Isto se deve ao fato de que a intenção aqui é apenas validar a proposta da CLARINet, abrindo perspectivas para aplicações mais avançadas que vão além da realização de experimentos preliminares.

O problema de navegação autônoma a ser tratado consiste na coleta de lixo, evitando-se colisões e mantendo-se a energia interna. Este problema de navegação foi modelado inicialmente por PFEIFER & SCHEIER (1999) e consiste na conservação da integridade do robô, associada ao seu nível interno de energia, sem negligenciar o atendimento dos demais objetivos.

Em 1999, WATANABE *et al.* (1999) investigaram um sistema de controle autônomo de um robô móvel baseado na teoria da rede imunológica para este problema de coleta de lixo proposto por PFEIFER & SCHEIER (1999). WATANABE *et al.* (1999) também empregaram uma rede imunológica para governar a navegação do robô.

Em linhas gerais, entre os múltiplos objetivos, o robô precisa encontrar e coletar o lixo, levando-o até uma base, evitando ao mesmo tempo colisões e mantendo o seu nível de energia interno (a base é o ponto de coleta de lixo e de recarga de energia). Os maiores problemas da proposta de Watanabe e colaboradores (WATANABE *et al.*, 1999) residem na necessidade de definição prévia não somente do conteúdo das células da rede imunológica (as quais definem as ações pontuais a serem tomadas pelo robô), mas também das conexões da rede. A eficiência deste modelo é restrita a sistemas de baixa complexidade, passíveis de descrição por uma rede pequena e simples que possa ser projetada manualmente.

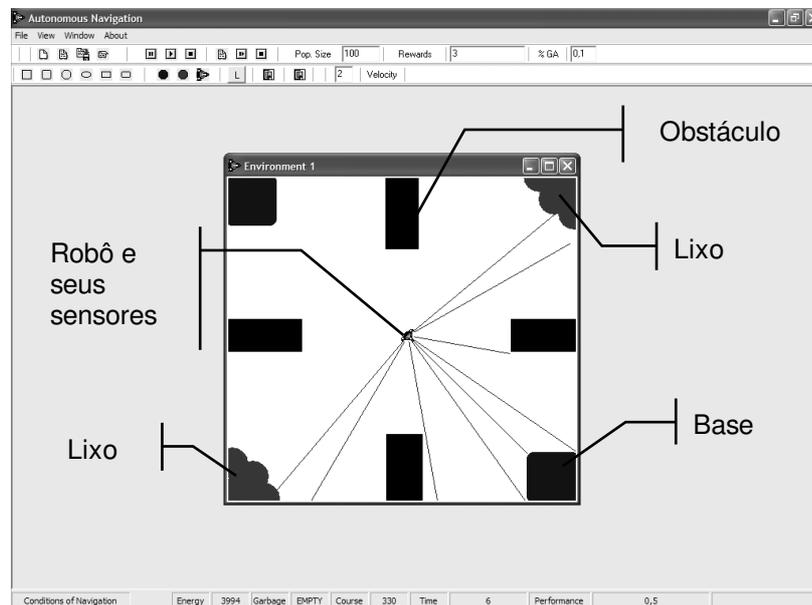
Neste caso, o desempenho do sistema está associado ao conteúdo das células imunológicas e às suas conexões. A partir do primeiro trabalho de Watanabe e colaboradores

(WATANABE *et al.*, 1999), conjecturou-se a possibilidade de se determinar automaticamente o conteúdo e o padrão de conexão das células imunológicas. Até o momento, duas abordagens foram propostas na literatura, WATANABE *et al.* (1998) e MICHELAN & VON ZUBEN (2002), com a finalidade de solucionar especificamente o problema de determinação automática das conexões. Ambos utilizam computação evolutiva para definir as conexões da rede imunológica automaticamente. As principais diferenças entre as duas abordagens residem nas formas de codificação e evolução das conexões (idiotopos), o que impede a equivalência entre as propostas. Ambas foram bem sucedidas e apresentam resultados promissores.

Já com a CLARINet, o objetivo é definir automaticamente não somente as conexões, mas também o conteúdo das células imunológicas, ou seja, quais ações pontuais devem ser tomadas pelo sistema. Além disso, a dinâmica da rede imunológica não é mais a única responsável pela determinação da célula vencedora. Deste modo, procurar-se-á validar a nova abordagem unificada da rede imunológica de classificadores como uma ferramenta com potencial para solucionar problemas dinâmicos que requerem um alto grau de flexibilidade. Na realidade, pode-se argumentar que a aplicação da CLARINet a este problema específico de navegação autônoma de robôs trata-se de mais uma tentativa de *modelagem dinâmica da cognição*. Conforme mencionado no Capítulo 1, de acordo com VAN GELDER & PORT (1995) e VAN GELDER (1995), esta *hipótese dinâmica em ciência cognitiva*, ou simplesmente *cognição dinâmica*, representa uma melhor opção de modelagem (ou metáfora) em oposição aos modelos computacionais tradicionais. De fato, no tocante a modelos para cognição artificial espera-se que abordagens dinâmicas sejam capazes de modelar mais eficazmente comportamentos típicos de agentes biológicos (THOMAS, 1997).

### 5.2.3 Um Cenário para Simulação

Propõe-se um cenário ilustrado na Figura 5.5 para simulação do sistema de navegação<sup>§§</sup>. O cenário ilustrado apresenta duas bases, dois depósitos de lixo, quatro obstáculos e um robô



**Figura 5.5 – O robô, seus sensores e o ambiente com duas bases, dois depósitos de lixo e quatro obstáculos.**

com sensores pontuais na forma de retas que têm sua origem em um ponto central do robô.

O robô ocupa aproximadamente 16x16 pixels da tela do cenário (Figura 5.5). Dada uma direção, ele apresenta um movimento de rotação máxima de 15° graus por passo e de 1° a 10° graus quando o comportamento exploratório é acionado. Quando há colisão, o robô executa um giro de 180°. Ele percorre 2 pixels por passo e recebe uma energia inicial de 4000 unidades, sendo que 2000 unidades é o limiar que caracteriza energia baixa.

O campo de visão se estende por 400 pixels a partir do centro do robô. Existem treze sensores divididos em três tipos: 1 interno ou de energia, 9 de cor (identificando obstáculo, lixo ou base) e 3 de colisão. Todos os sensores com exceção do sensor interno são pontuais, ou seja, são retas imaginárias que têm origem no centro do robô. Os nove sensores de cor detectam distância, cor e posição. Todos os parâmetros foram adotados com base nas simulações retratadas no trabalho de MICHELAN & VON ZUBEN (2002).

Como o robô precisa ser auto-suficiente, um aspecto importante a ser considerado reside

§§ O ambiente de simulação utilizado foi desenvolvido por Roberto Michelan (MICHELAN, 2003).

na dinâmica de consumo de energia do robô. Isto requer um chaveamento gradual de contexto entre os objetivos do robô de forma a manter a sua integridade. Repare que a energia interna do robô não tem qualquer associação direta com a energia ou *strength* dos classificadores vinculados ao módulo de controle autônomo.

A dinâmica da energia é a medida que reflete como o nível de energia varia a cada iteração. Este nível de energia depende de quatro parâmetros:

- 1) O nível de energia da iteração anterior,  $E(t - 1)$ ;
- 2) O consumo de energia por iteração,  $E_m$ ;
- 3) A energia adicional consumida quando o robô está carregando lixo,  $E_g$ ;
- 4) A perda de energia quando ocorre colisão com um obstáculo,  $E_c$ ;

O nível de energia do robô a cada iteração  $t$ ,  $E(t)$ , é calculado pela equação:

$$E(t) = E(t - 1) - E_m - k_1 E_g - k_2 E_c, \quad \text{Equação 5.3}$$

Onde:

$$k_1 = \begin{cases} 1 & \text{se carregando lixo} \\ 0 & \text{caso contrário} \end{cases},$$

$$k_2 = \begin{cases} 1 & \text{se o robô colide com um obstáculo ou parede} \\ 0 & \text{caso contrário} \end{cases}$$

A cada iteração, o nível de energia é reduzido de um valor fixo de energia  $E_m$ . As constantes  $k_1$  e  $k_2$  indicam que o nível de energia somente será reduzido pela quantia respectiva se o robô estiver carregando lixo e/ou colidir com algum obstáculo.

Nas simulações a serem apresentadas, foram adotados os seguintes valores para os parâmetros:  $E_m = 1$ ,  $E_g = 3$  e  $E_c = 5$ . Estes valores revelam que o consumo de energia é maior quando o robô colide do que quando ele simplesmente está carregando lixo.

## 5.2.4 Modelagem do Problema

De início, os sensores do robô recebem estímulos internos e do ambiente. Em seguida, os transformam em mensagens relacionadas ao estado atual do robô. É importante recordar que essas mensagens desempenham o papel de antígenos para a CLARINet.

### 5.2.4.1. Codificação das Mensagens (Antígenos)

As mensagens (ou antígenos) são codificadas como vetores binários de 6 (seis) bits, sendo que apenas o primeiro bit pode assumir quatro valores distintos: 1: lixo; 2: obstáculo; 3: base e 4: energia.

No caso do primeiro bit assumir os valores 1(lixo), 2(obstáculo) ou 3 (base), o restante dos bits seguem o seguinte padrão:

- 1 DFE UU
- 2 DFE UU
- 3 DFE UU

Onde os bits “D”, “F” e “E” codificam a existência (“1”) ou não (“0”) do referido item (lixo, obstáculo ou base) respectivamente à direita (“D”), à frente (“F”) e/ou à esquerda (“E”). Os dois últimos bits UU codificam a distância ou a existência do referido item (lixo, obstáculo ou base): 11 - perto, 10 - médio, 01 - longe e 00 - não existe.

No caso do primeiro bit assumir o valor 4 (energia), temos:

- 4 000 N0

O bit N assume (1) em caso de energia alta e (0) em caso de energia baixa.

O número de antígenos é sempre menor ou igual ao número de sensores, sendo que antígenos repetidos são retirados do sistema, ou seja, a rede vê apenas um exemplar de cada antígeno.

#### 5.2.4.2. Codificação dos Classificadores (Anticorpos)

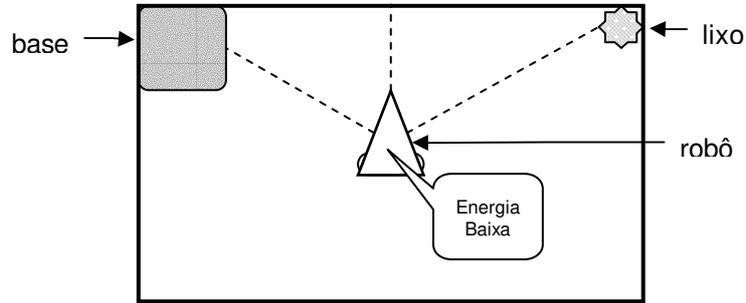
O robô, através da CLARINet, possui uma rede imunológica de classificadores (ou anticorpos na forma de regras do tipo condição/ação) que tentam realizar casamento de padrões com as mensagens provenientes do ambiente e de seu estado interno. Acompanhando os passos descritos na Seção 5.1.3, o robô irá decidir qual será a ação mais apropriada para a situação.

Seguindo o modelo ilustrado na Figura 5.2, um classificador é codificado pela concatenação de um vetor de 8 (oito) posições (paratopo) dividido em duas partes: antecedente e conseqüente e, um vetor de conexões (idiotopo), que indica a quais outros classificadores ele está conectado.

A parte antecedente possui seis bits, onde o primeiro que corresponde à *tag* pode assumir quatro valores distintos: 1: lixo; 2: obstáculo; 3: base e 4: energia. Os outros cinco bits restantes são formados pela concatenação de elementos do alfabeto ternário {0, 1, #}. A parte conseqüente segue a codificação binária em um vetor de dois bits, os quais codificam as possíveis ações do robô: 11 - vire à esquerda, 10 - siga em frente, 01 - vire à direita e 00 - movimento randômico (ou de exploração do ambiente).

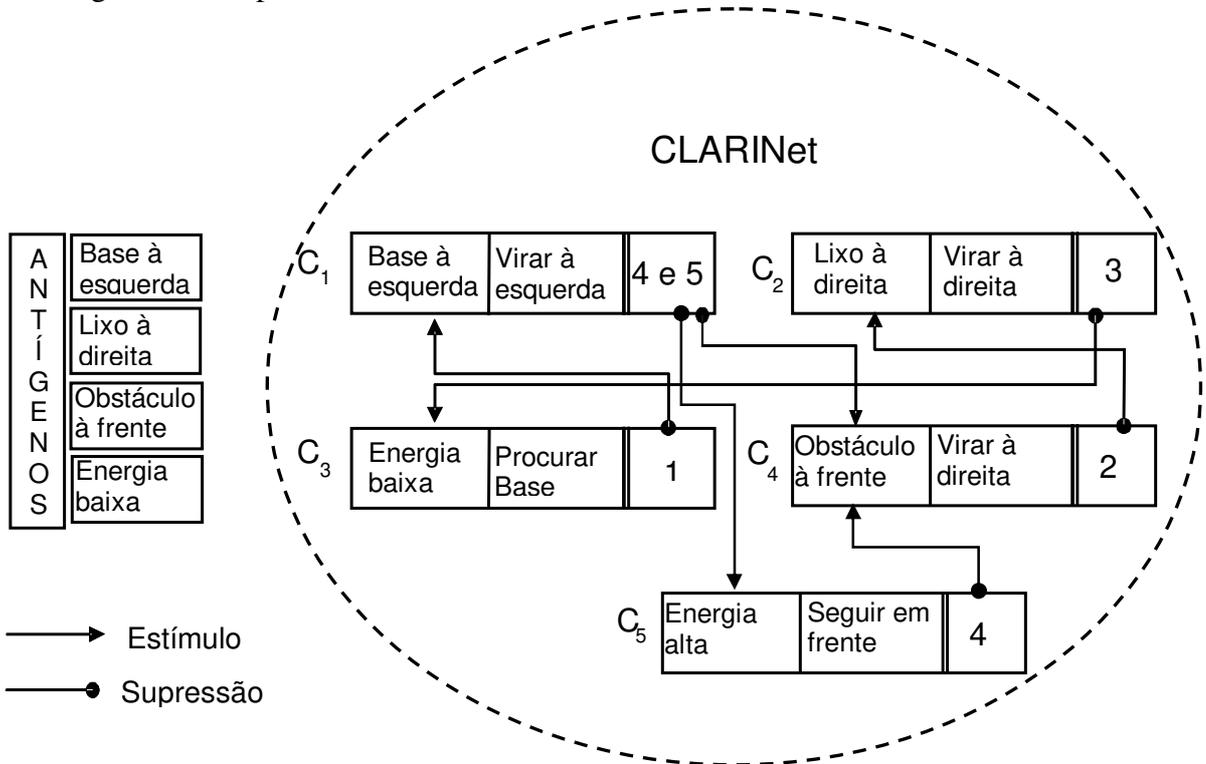
#### 5.2.4.3. Exemplo de Codificação das Mensagens e dos Classificadores

Desenvolveu-se um exemplo didático que procura ilustrar com clareza a codificação da CLARINet para o problema específico de navegação autônoma citado na Seção 5.2.2. Para tal, toma-se como referência a posição de um agente robótico em relação ao ambiente como ilustrado na Figura 5.6. O robô está posicionado de frente para uma parede e seus sensores detectam base à esquerda, lixo à direita, obstáculo à frente (parede) e nível de energia interna baixo.



**Figura 5.6– Posição de um agente robótico em relação ao seu ambiente, incluindo uma base, um lixo e obstáculos.**

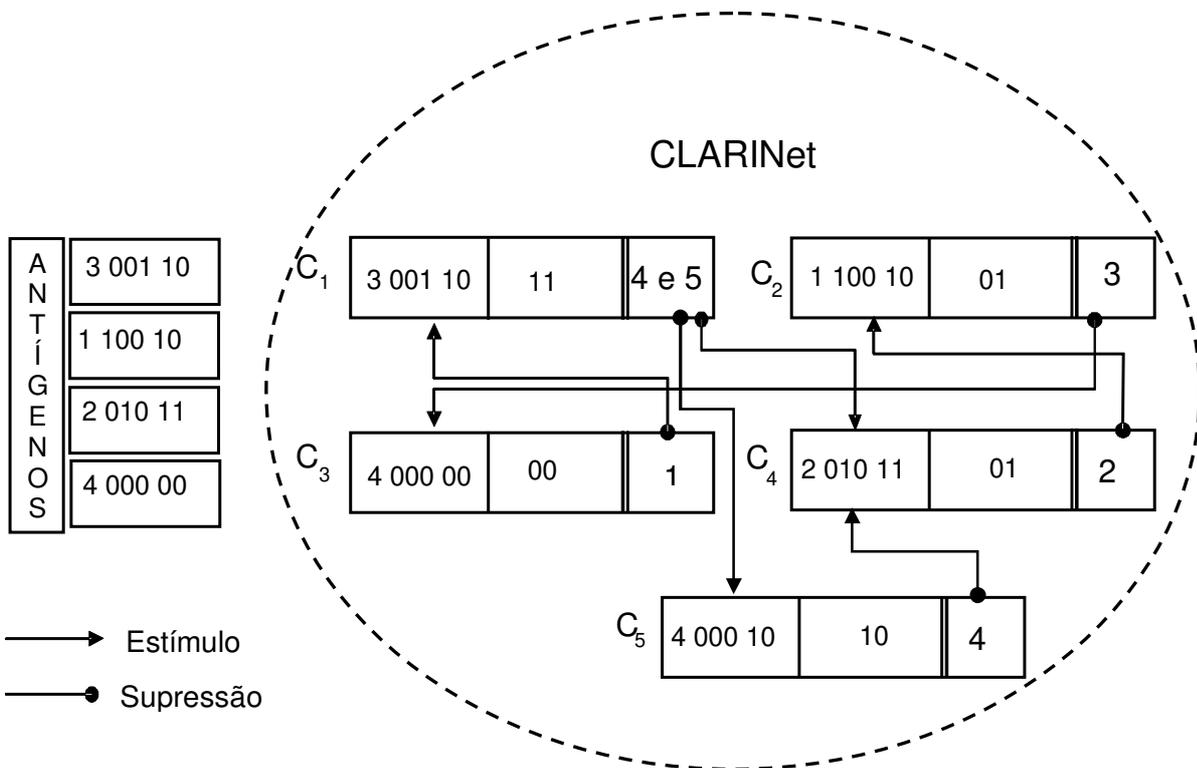
Dada a leitura dos sensores, os possíveis antígenos são ilustrados na Figura 5.7 juntamente com a estrutura de uma CLARINet que comanda a navegação autônoma deste agente robótico. A CLARINet apresentada pode corresponder a uma parte de uma rede imunológica mais ampla.



**Figura 5.7 - Exemplo dos possíveis antígenos para a situação ilustrada na Figura 5.6, juntamente com uma rede imunológica de classificadores (CLARINet) que comanda a navegação do agente robótico.**

A CLARINet ilustrada na Figura 5.7 é formada por 5 classificadores e suas conexões. Observa-se que cada antígeno é identificado por um classificador. De acordo com a dinâmica descrita pela Fase 1 (Seção 5.1.3), os classificadores que se identificarem com as mensagens (ou antígenos) devem passar pelo procedimento padrão dos SC originais, o qual irá apontar um vencedor: o classificador antigênico. Em seguida, passa-se para a Fase 2, a qual irá revelar o classificador *ativado*.

Não é objetivo desta seção descrever toda a dinâmica do processo, mas sim exemplificar a codificação das mensagens do ambiente e dos classificadores na CLARINet, como ilustrado na Figura 5.8, referente à codificação do exemplo apresentado na Figura 5.7.



**Figura 5.8– Exemplo de codificação dos antígenos (ou mensagens) do ambiente ilustrado na Figura 5.6 e de uma rede imunológica de classificadores (CLARINet) para comandar a navegação autônoma do agente robótico em questão.**

A codificação esboçada na Figura 5.8 segue as regras de codificação apresentadas nas Seções 5.2.4.1 e 5.2.4.2 para mensagens do ambiente e classificadores da rede. Nota-se que

esses classificadores são específicos, pois não possuem o símbolo “don’t care” (“#”) em sua parte antecedente. Repare também que o cenário ilustrado na Figura 5.8 indica a existência de anticorpos com parte antecedente idênticas aos antígenos. Numa situação prática, este casamento completo de padrões e a existência de pelo menos um anticorpo para cada antígeno pode não se verificar, o que não impede que o sistema opere adequadamente.

É interessante observar que a situação retratada na Figura 5.6, na qual o robô está com energia interna baixa, encontra uma base à sua esquerda, um lixo à sua direita e um obstáculo à sua frente, estimularia os classificadores 1, 2, 3 e 4 de forma que uma tomada de decisão razoável seria representada pela ativação do classificador 1 ( $C_1$ ), o qual indica que o robô deve se movimentar virando à esquerda (em direção a base), para recarregar a bateria. Ressalta-se que, caso o robô estivesse com a energia interna alta, os classificadores estimulados seriam 1, 2, 4 e 5 e a dinâmica da rede deveria apontar para uma movimentação do robô para a direita, em direção ao lixo ( $C_2$ ).

Como mencionado anteriormente, tanto os classificadores quanto suas conexões devem passar por um processo de evolução e aprendizado, procurando adaptar-se a cenários dinâmicos através da emergência de comportamento inteligente. De início, esta emergência de comportamento deve ocorrer sem um conhecimento prévio, ou seja, na ausência de um modelo interno do ambiente. Apresentam-se, a seguir, aspectos intrínsecos da evolução da rede imunológica de classificadores.

### **5.2.5 Evolução e Aprendizado da Rede Imunológica de Classificadores**

Como é usual na implementação de sistemas computacionais bio-inspirados, os parâmetros adotados foram definidos empiricamente e ajustados ao problema específico a ser tratado, embora pudessem sofrer um processo de ajuste durante a operação do sistema. É comum a adoção de processos de relaxação em que o nível de ajuste paramétrico decai exponencialmente com o número de iterações do processo de ajuste. Como exemplo, é possível mencionar os mecanismos de ajuste em aprendizado não-supervisionado para síntese de mapas

auto-organizáveis (KOHONEN, 1997). Portanto, existem boas perspectivas para a implementação de mecanismos de auto-ajuste, embora estes não sejam adotados aqui.

O processo de aprendizagem por reforço inicia com todos os classificadores e suas conexões criadas aleatoriamente. Isso implica que a rede inicia o procedimento de aprendizagem sem uma representação interna do ambiente, a qual deverá ser adquirida durante o processo evolutivo. Na realidade, essa ausência de conhecimento inicial retrata um aspecto interessante da CLARINet, onde tanto os componentes da rede (os classificadores) quanto as conexões são ajustáveis durante a operação do sistema.

As duas fases de operação e ajuste da CLARINet (Figura 5.4, Seção 5.1.4), associadas à aplicação do algoritmo genético a cada *época* (Seção 5.1.3), compõem *ciclos de operação, ajuste e evolução* da CLARINet ao longo das interações com o ambiente. O *ciclo de ajuste* inicia-se através da alteração da energia dos classificadores envolvidos no processo através de sinais de reforço, os quais podem ser sinal de recompensa ou sinal de punição. Pode ocorrer recompensa em duas situações:

- 1) o robô recarregou sua energia quando se encontrava com um nível baixo de energia interna e;
- 2) o robô coletou lixo quando estava com um nível alto de energia interna.

A punição ocorre quando:

- 1) o robô coleta lixo estando com um nível baixo de energia interna e;
- 2) o robô colide com algum obstáculo ou parede.

Através deste processo de aprendizagem por reforço, o robô evolui seu comportamento tornando-se capaz de distinguir ações que resultam em punição de ações que resultam em recompensa.

Durante o *ciclo evolutivo*, os classificadores e suas conexões passam por um processo evolutivo com a aplicação de um algoritmo genético a cada 500 iterações com o ambiente. Este número determina a extensão da *época* ou intervalo de aplicação do algoritmo genético.

Na aplicação do algoritmo genético, faz-se o cruzamento dos melhores classificadores (os de maior energia) sem se considerar a quantidade de exemplares de cada nicho. Considera-se

como nicho todos os classificadores de uma mesma *tag*. Recorda-se que cada classificador identifica somente mensagens com *tag* idêntica à sua. Emprega-se o *crossover* de um ponto em cada parte do anticorpo separadamente, ou seja, na parte antecedente e conseqüente, e na parte das conexões ou idiotopo. Procura-se cruzar apenas exemplares de mesmo nicho à taxa de 10% e aplica-se também mutação à taxa de 1%. Ao final do processo, substituem-se os piores indivíduos da população pela percentagem de filhos gerados (10% da população) seguindo-se os mesmos critérios que consideram o nicho ao qual pertence cada filho.

### **5.2.6 Resultados Preliminares**

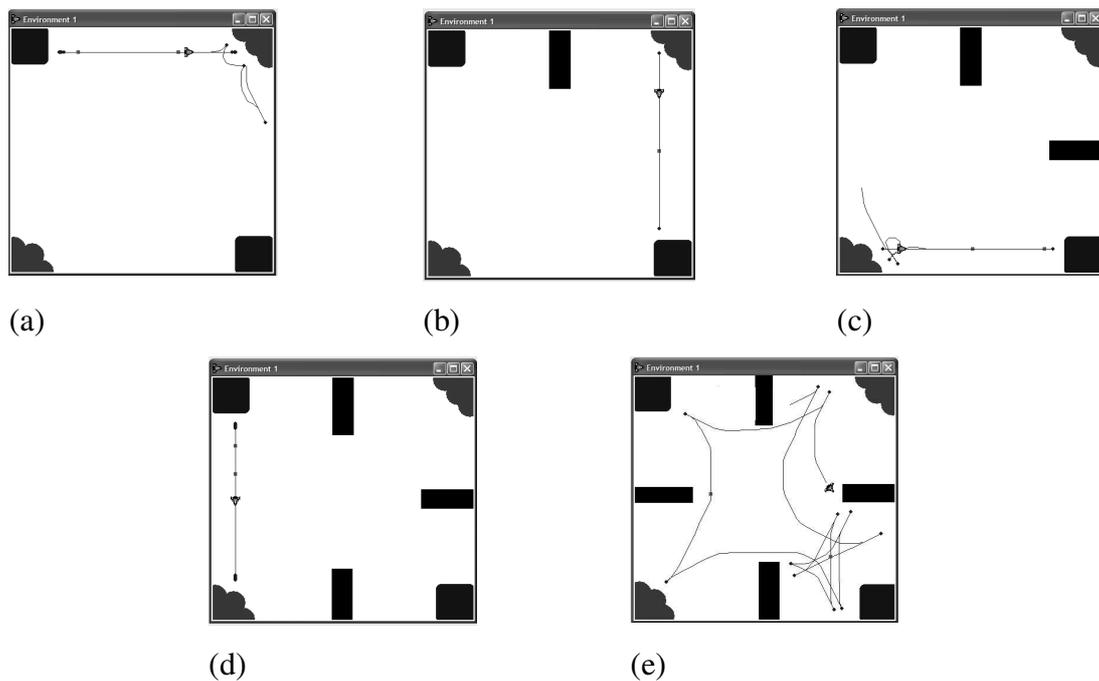
Esta sub-seção apresenta alguns resultados preliminares obtidos com a aplicação da CLARINet na simulação do sistema de navegação autônoma, recorrendo-se ao ambiente de navegação apresentado na Figura 5.5. Como foi mencionado na Seção 5.2.3, para poder avaliar a abordagem proposta, desenvolveu-se um ambiente de simulação flexível e adaptado ao problema de coleta de lixo. Portanto, existem várias possibilidades de configuração do ambiente, incluindo forma, localização e quantidade de seus componentes.

Nos testes preliminares, espera-se que o robô atinja um comportamento cíclico, o qual corresponderá a uma seqüência de ações que o levam do lixo à base e vice-versa. Como poderá ser observado junto aos resultados das simulações, a trajetória mais curta entre o lixo e a base normalmente é a escolhida.

Os experimentos a serem apresentados seguem um protocolo particular. Os obstáculos da Figura 5.5 são inseridos no ambiente um de cada vez, obedecendo a intervalos regidos pelo comportamento do robô. Isto é, cada vez que o robô atinge um comportamento cíclico, insere-se um novo obstáculo, visando impedir que o robô prossiga na mesma trajetória e, portanto, cria-se um novo cenário. Este procedimento foi seguido até inserir-se todos os quatro obstáculos da Figura 5.5. As razões para estas intervenções são duas: (1) evitar monotonia; (2) estudar o comportamento do robô frente a uma nova situação. Estas mudanças no ambiente também servem para explorar a capacidade da CLARINet de conduzir o processo de tomada de decisão

de modo que o robô opere em ambientes dinâmicos.

Neste primeiro experimento, o robô inicia a navegação sem nenhum conhecimento. Restringiu-se empiricamente o tamanho da população a 100 (cem) classificadores e suas conexões na ordem de 70%. Isto significa que cada classificador pode estar conectado a 70% da população, ou seja, seu vetor de conexões está com 70% das posições possíveis ocupadas. Por exemplo, suponha que existem 10 classificadores que formam uma CLARINet; caso se defina que suas conexões são da ordem de 70%, cada classificador poderá estar conectado no máximo a outros 7 classificadores e assim por diante. Tanto os classificadores quanto as conexões foram criados aleatoriamente, sendo que o número total de classificadores (tamanho da população) é mantido *inalterado*.



**Figura 5.9 – Avaliação do comportamento da CLARINet. (a) O primeiro ambiente sem obstáculos (somente com as paredes, bases e lixos). (b) O segundo ambiente com um obstáculo. (c) O terceiro ambiente com dois obstáculos. (d) O quarto ambiente com três obstáculos. (e) O quinto ambiente com quatro obstáculos. A posição de inserção de cada obstáculo é escolhida visando forçar o robô a buscar uma trajetória alternativa àquela ilustrada no ambiente anterior.**

A Figura 5.9 mostra as últimas 250 iterações do robô em cada ambiente após atingir um comportamento cíclico. Seguindo-se o protocolo descrito anteriormente, a Figura 5.9 (a) ilustra o ambiente inicial sem obstáculos. O robô encontrou uma trajetória que o conduziu do lixo para a base e vice-versa, atingindo um comportamento estável sem colisões após 21.200 iterações em média. Como já era esperado, este comportamento só foi atingido após uma exploração completa do ambiente, incluindo várias colisões.

Após este período inicial de aprendizado, os obstáculos foram inseridos um a um. Na Figura 5.9 (b) o robô encontra automaticamente uma trajetória alternativa para lidar com seus múltiplos objetivos. É relevante observar que o robô troca a base utilizada para recarga e entrega do lixo. Desta forma, ele escolhe o caminho mais curto do lixo até a base.

Nos terceiro e quarto cenários, Figura 5.9 (c) e (d), o robô sempre encontra uma solução parcimoniosa, trocando de base para recarga e escolhendo sempre o caminho mais curto. O robô necessitou, em média, 7.000 iterações para atingir um comportamento estável após cada mudança do ambiente

Em todos os experimentos descritos até então, o robô foi capaz de reagir prontamente às mudanças no ambiente, representadas aqui pela inserção de novos obstáculos de tempos em tempos. A CLARINet forneceu ao robô autônomo a habilidade necessária (plasticidade) para adaptar-se a novos cenários enquanto lidava com objetivos conflitantes (coleta de lixo e manutenção de sua integridade). Observa-se na Figura 5.9 (e) que, mesmo na presença de um novo cenário mais complexo, o robô foi capaz de encontrar uma trajetória alternativa. Interessante notar que todos os comportamentos adotados até então foram descartados e novos procedimentos de navegação foram estabelecidos.

### **5.2.7 Análise do Experimento e Resultados**

Alguns pontos críticos foram observados no decorrer dos experimentos. A primeira dificuldade apontada refere-se à definição empírica de vários parâmetros da rede, a começar pelo tamanho da população e número de conexões iniciais. A segunda refere-se à determinação da

extensão da *época* ou do intervalo ideal de aplicação do processo evolutivo (emprego do algoritmo genético). Observou-se que, em ambos os casos, o sistema apresentou-se sensível a pequenas alterações nesses parâmetros, levando o sistema a comportamentos aleatórios caracterizados pela ausência de indicativos de aprendizado ao longo do tempo.

Aspectos particulares do cenário adotado para simulação também devem ser considerados. Por exemplo, a utilização de sensores pontuais para o agente robótico dificulta a avaliação de alterações na dinâmica do ambiente sob a óptica do robô.

Com relação aos resultados, acredita-se que as atitudes parcimoniosas do robô estão relacionadas com uma característica do projeto, onde o robô gira 180° quando há contato com qualquer componente do ambiente. Articula-se que este aspecto leva o robô a procurar movimentar-se em linha reta quando o mesmo encontra estímulos nos dois extremos do caminho (base de um lado e lixo do outro). Apesar de na Figura 5.9 (e) o robô ter apresentado um comportamento distinto dos adotados até então, diferentemente do que ocorreu nas Figuras 5.9 (a), (b), (c) e (d), o robô foi capaz de executar este caminho uma única vez, voltando a colidir em seguida e não conseguindo retomar o comportamento anterior. A perda da diversidade ao longo das iterações pode ser a justificativa para tal comportamento.

Nota-se que a rede imunológica resultante do processo evolutivo apresenta uma alta densidade de conexões, acima de 70%, o que já era esperado seguindo os resultados anteriores obtidos por MICHELAN & VON ZUBEN (2002). Salienta-se novamente que MICHELAN & VON ZUBEN (2002) propuseram um controle autônomo baseado apenas em uma rede imunológica, sendo que as células da rede são definidas *a priori* e apenas as conexões sofrem evolução ao longo da navegação.

A perda de diversidade das células da rede ou classificadores representou um outro aspecto crítico na reposta imediata e manutenção de comportamento frente a mudanças no ambiente. Com o passar das iterações, observa-se também uma tendência ao predomínio de classificadores de uma determinada *tag* sobre outros. Presume-se que esta predominância esteja vinculada à trajetória escolhida pelo robô, a qual conseqüentemente determina os antígenos aos quais ele estará exposto. Uma mesma seleção que se repete ao longo do tempo pode levar a

CLARINet à criação de um conjunto de especialistas (classificadores de mesma *tag*) voltados ao *combate* destes antígenos específicos.

Procura-se explicitar a seguir algumas sugestões adicionais indicativas a investigações futuras.

Durante o processo de aprendizagem, sugere-se que a recompensa seja incorporada:

- 1) ao classificador antigênico;
- 2) ao classificador ativado;
- 3) a todos que estão ligados ao classificador ativado via conexões, ou seja, para todos que estão estimulando o classificador ativado;
- 4) a todos que se identificaram com o antígeno.

Além disso, sugere-se inserir no idiotopo de todos que se identificaram com o antígeno o número do classificador ativado. Desta forma, reforça-se o estímulo ao classificador ativado, aumentando sua concentração.

Quanto à punição, acredita-se que se deve aplicá-la:

- 1) ao classificador antigênico;
- 2) ao classificador ativado;
- 3) a todos que estão ligados ao classificador ativado via conexões, ou seja, a todos que estão estimulando o classificador ativado.

Além disso, sugere-se retirar do idiotopo de todos que se identificaram com o antígeno o número do classificador ativado. Desta forma, diminui-se o estímulo ao classificador ativado.

O passo 4) sugerido na recompensa não está incluso na punição, pois acredita-se que não se deve punir os classificadores que se identificaram com o antígeno, pois eles podem ser potenciais candidatos na próxima iteração com o mesmo antígeno. Conjetura-se que este procedimento pode ajudar a enfatizar conexões entre classificadores de mesma *tag*.

Outra proposta seria incrementar o operador de seleção do classificador ativado, criando uma aleatoriedade e diversificando a atuação do sistema mesmo na presença de classificadores com o mesmo nível de ativação.

Ao mesmo tempo em que se reconhece a dificuldade intrínseca da tarefa de síntese da

CLARINet, com evolução simultânea de células e conexões, ressalta-se a existência de implementações bem-sucedidas de redes imunológicas para navegação autônoma (MICHELAN, 2003) e de sistemas classificadores com aprendizado para o mesmo fim (CAZANGI, 2004). Vargas e colaboradores (VARGAS *et al.*, 2002) também já demonstraram a equivalência desses dois sistemas, a qual foi devidamente explorada na concepção da CLARINet (VARGAS *et al.*, 2003b). O emprego da CLARINet junto a problemas que não envolvem comportamentos cíclicos e uma investigação de mecanismos sistemáticos de interpretação da rede de classificadores resultante do processo evolutivo serão objeto dos próximos passos da pesquisa.

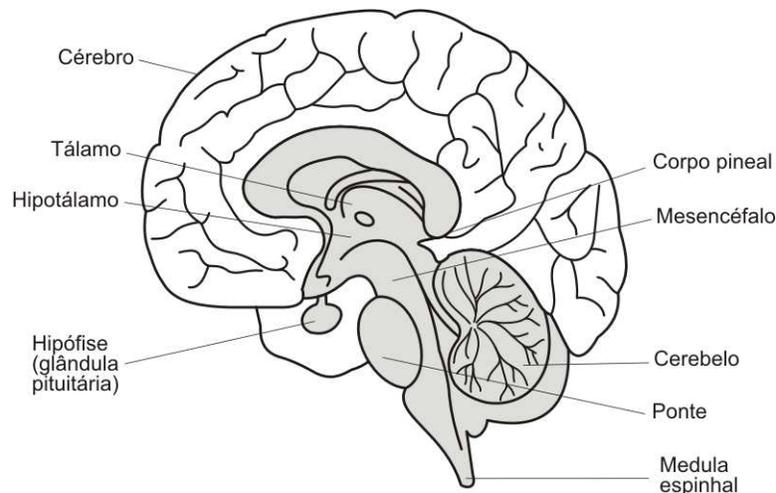
## **6. PROJETO E SÍNTESE DE SISTEMAS HOMEOSTÁTICOS ARTIFICIAIS**

<b>6. PROJETO E SÍNTESE DE SISTEMAS HOMEOSTÁTICOS ARTIFICIAIS</b> .....	109
6.1. A Interação Neuro-Endócrina na Espécie Humana .....	109
6.2. Sistema Homeostático Artificial: Trabalho Anterior .....	113
6.2.1 Implementação da Rede Neural Artificial e do Sistema Endócrino Artificial .....	114
6.3. Sistema Homeostático Artificial: Uma Nova Proposta .....	118
6.3.1 Projeto das Redes Neurais Artificiais .....	118
6.3.2 Projeto do Sistema Endócrino Artificial.....	119
6.3.3 Dinâmica do Sistema .....	121
6.4. Aplicação: Robótica Autônoma.....	126
6.4.1 Experimento I .....	129
6.4.2 Experimento II.....	136
6.4.3 Experimento III .....	144
6.4.4 Experimento IV.....	149
6.4.5 Análise dos Experimentos e Resultados.....	155

Este capítulo se inicia com uma descrição de circunstâncias peculiares da biologia envolvida na interação do sistema nervoso com o sistema endócrino na espécie humana, estendendo conceitos expostos no capítulo 3, seções 3.2.2 e 3.2.4. Em seguida, é descrito um dos trabalhos relevantes na área de sistemas homeostáticos artificiais, o qual apresenta uma proposta inicial de uma versão artificial de um sistema endócrino. Segue-se a proposta de uma abordagem integrada de um sistema homeostático artificial envolvendo redes neurais artificiais e um novo modelo de sistema endócrino artificial. Apresenta-se, por fim, uma aplicação do sistema proposto em navegação autônoma de robôs, incluindo simulações computacionais e experimentos com robôs reais do tipo Khepera II<sup>®</sup>.

### **6.1. A Interação Neuro-Endócrina na Espécie Humana**

A interação do sistema nervoso com o sistema endócrino mais relevante ao escopo desta tese ocorre entre o hipotálamo e a glândula pituitária (ou hipófise) (BESENDOVSKY & DEL REY, 1996). O hipotálamo é uma região do cérebro localizada abaixo do tálamo (Figura 6.1).

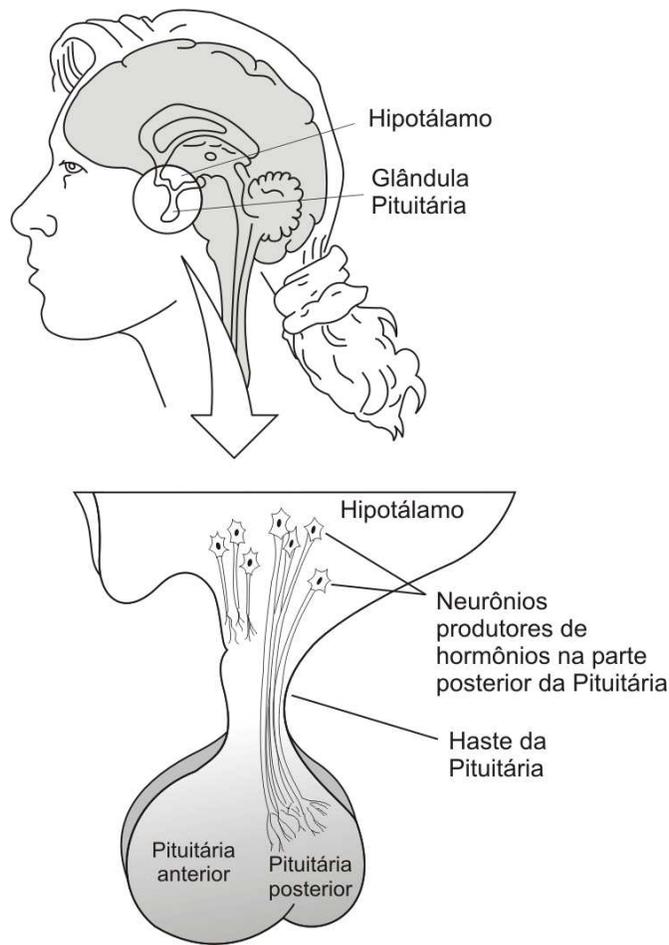


**Figura 6.1 – Localização do hipotálamo dentro do cérebro (adaptado de PURVES *et al.* (2001)).**

O hipotálamo consiste de várias agregações de células nervosas e sua principal função é controlar a liberação de hormônios da glândula pituitária. De fato, devido a esta interação, nas últimas três décadas o hipotálamo tornou-se conhecido também como o “hipotálamo endócrino” (GREGER & WINDHORST, 1996; GUYTON & HALL, 1996).

A glândula pituitária ou hipófise é também designada glândula mestra e está localizada na base do cérebro (Figura 6.2). Ela possui dois lobos: anterior e posterior. O lobo posterior armazena e libera hormônios no sangue, enquanto que o lobo anterior é glandular, pois possui como principal objetivo liberar hormônios que controlam a atividade de várias outras glândulas endócrinas. Recorda-se que vários hormônios circulam pelo corpo humano, sendo que cada um estimula órgãos e células predefinidos, através de ligações físico-químicas entre o hormônio e *receptores* específicos presentes normalmente na superfície desses órgãos e células.

O hipotálamo contém neurônios que controlam a liberação de hormônios dos lobos anterior e posterior da glândula pituitária. Este controle ocorre por duas vias: conexão direta entre o lobo posterior e os neurônios do hipotálamo através da haste da pituitária; e conexão indireta por meio dos hormônios do hipotálamo que atingem o lobo anterior da glândula pituitária através de vasos sanguíneos (Figura 6.2).

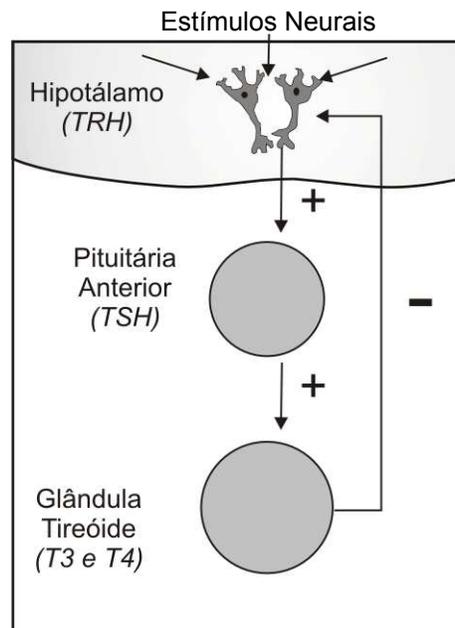


**Figura 6.2 – Localização e anatomia da glândula pituitária ou hipófise (adaptado de PURVES *et al.* (2001)).**

Na conexão indireta, sete hormônios do hipotálamo são liberados no sistema de acoplamento que conecta o hipotálamo à pituitária, o que provoca a reação de alvos predeterminados dentro da pituitária a liberar oito tipos de hormônios. Esses hormônios, por sua vez, irão controlar outros órgãos e outras glândulas endócrinas.

Como a maioria dos sistemas hormonais, a interação hipotálamo-pituitária é controlada por mecanismos de retroalimentação. Existe a retroalimentação positiva e a retroalimentação negativa. A retroalimentação positiva distingue-se pelo caráter excitativo de produção e liberação de hormônios. Já a retroalimentação negativa apresenta uma característica inibitória de produção e liberação de hormônios.

Normalmente, a maioria das funções fisiológicas é regulada por ciclos de retroalimentação negativa (GUYTON & HALL, 1996). Na interação hipotálamo-pituitária, existem ciclos curtos e longos controlando o sistema. A liberação de hormônios no hipotálamo é regida não somente por estímulos neurais, mas também por estes ciclos de retroalimentação. A Figura 6.3 exemplifica mecanismos de excitação em cascata com retroalimentação negativa entre o hipotálamo, a glândula pituitária e a glândula tireóide.



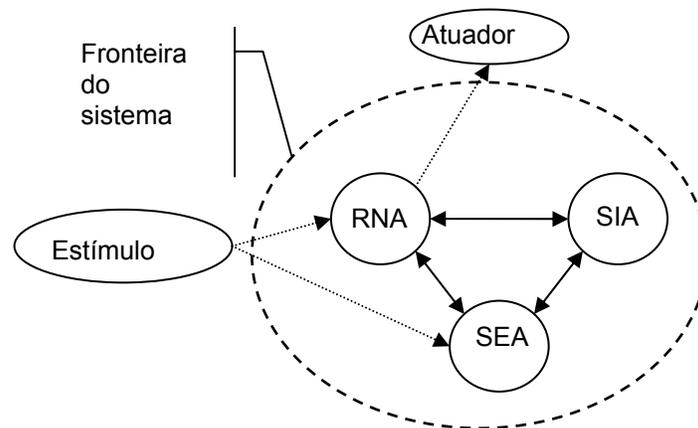
**Figura 6.3 – Um exemplo de uma excitação em cascata (sinal +) e retroalimentação negativa (sinal –) entre o hipotálamo, a glândula pituitária e a glândula tireóide.**

Note que o hipotálamo libera hormônio TRH, que estimula a produção do hormônio TSH na pituitária (excitação), que, por sua vez, estimula a produção dos hormônios T3 e T4 na glândula da tireóide (excitação). O aumento no nível de concentração dos hormônios T3 e T4 na corrente sanguínea leva à inibição da produção de TRH pelo hipotálamo (retroalimentação negativa), o que diminui a concentração do TSH, causando assim a inibição do estímulo à produção de T3 e T4 pela tireóide. Quando as concentrações de T3 e T4 diminuem na corrente sanguínea, cessa a retroalimentação negativa e o hipotálamo volta a produzir o hormônio TRH, reiniciando o ciclo.

Em linhas gerais, os mecanismos e ciclos de retroalimentação são governados por outros três mecanismos: um sensor responsável pela medição de variáveis controladas que estão sob supervisão, um ponto de referência e um sinal de erro (GREGER & WINDHORST, 1996). Em algumas circunstâncias, os mecanismos de retroalimentação tendem a produzir oscilação. No contexto de sistemas dinâmicos, a propensão a comportamentos oscilatórios é de grande interesse, por existirem comportamentos cíclicos na natureza e pela associação entre oscilação e estabilidade. Por este motivo, é primordial um amplo entendimento desses comportamentos para que se desvende corretamente boa parte das interações neuro-endócrinas, inclusive aquelas relevantes à solução de problemas de cognição dinâmica.

## 6.2. Sistema Homeostático Artificial: Trabalho Anterior

Em um trabalho anterior, TIMMIS & NEAL (2004) propuseram desenvolver um sistema homeostático artificial para controlar as ações de um agente robótico (Figura 6.4). Este sistema é composto por um modelo de sistemas endócrinos artificiais (SEA), envolvendo também redes neurais artificiais (RNA) e sistemas imunológicos artificiais (SIA).



**Figura 6.4 – Visão geral do sistema homeostático artificial integrado (adaptado de TIMMIS & NEAL (2004)).**

De acordo com os autores, a idéia é criar um sistema que proporcione a capacidade de manutenção do equilíbrio interno de um agente (e.g., um robô) enquanto o mesmo interage com um ambiente externo. Apesar desta proposta bastante abrangente, os autores restringiram-se ao desenvolvimento da interação neuro-endócrina, ou seja, da rede neural artificial com o sistema endócrino artificial, ficando assim a parte imunológica, ou do sistema imunológico artificial, como perspectiva futura. Por este motivo, na próxima seção, descrever-se-á apenas a parte neuro-endócrina do sistema homeostático ilustrado na Figura 6.4. É importante ressaltar que o escopo adotado por TIMMIS & NEAL (2004), o qual se restringe ao desenvolvimento, em uma primeira instância, exclusivamente da interação neuro-endócrina, será o mesmo aplicado na nova proposta a ser apresentada na Seção 6.3. A diferença está na proposição de um sistema endócrino mais elaborado e mais biologicamente plausível.

### **6.2.1 Implementação da Rede Neural Artificial e do Sistema Endócrino Artificial**

O desenvolvimento deste modelo de sistema homeostático artificial proposto por TIMMIS & NEAL (2004) começou com um trabalho de investigação de uma proposta mais simplista de interação neuro-endócrina, que envolve uma rede neural artificial e um modelo de sistema endócrino artificial (NEAL & TIMMIS, 2003). Em TIMMIS & NEAL (2004), os autores estenderam a proposta para incluir duas redes neurais artificiais.

Tanto em NEAL & TIMMIS (2003) como em TIMMIS & NEAL (2004), faz-se uso de modelos de redes neurais artificiais (HAYKIN, 1999) de múltiplas camadas do tipo MLP (“*multi-layer perceptron*”, na literatura em inglês), com funções de ativação do tipo sigmoidal. Em NEAL & TIMMIS (2003), as redes foram projetadas manualmente, ou seja, os pesos das conexões foram determinados pelos projetistas. Já em TIMMIS & NEAL (2004), os autores empregam o algoritmo de aprendizagem por retropropagação (HAYKIN, 1999) para treinar as redes. Entretanto, os autores não deixam explícito como são produzidos os dados para treinamento supervisionado.

Nos dois projetos, o sistema endócrino artificial é descrito como um sistema que emprega hormônios controladores, promovendo um mecanismo de controle regulável em médio prazo para o comportamento do sistema. Isto ocorre através da influência direta dos hormônios produzidos pelo sistema endócrino artificial sobre os pesos da(s) rede(s) neural(is) artificial(is). É oportuno destacar que, no modelo de rede neural artificial adotado pelos autores nos dois projetos, cada neurônio artificial contempla *receptores* para os hormônios. Este aspecto define a sensibilidade de um determinado neurônio artificial a determinado hormônio.

Assim como a rede neural artificial, observa-se na Figura 6.4 que o sistema endócrino artificial também recebe estímulos do ambiente. O modelo do sistema endócrino artificial consiste de *glândulas* que liberam hormônios *armazenados* em um reservatório, em resposta a *estímulos externos*:

$$r_j = \alpha_j \sum_{i=1}^{nx} x_i \quad \text{Equação 6.1}$$

onde:

$r_j$  é a quantidade de hormônios liberada pela glândula  $j$ ;

$\alpha_j$  é a taxa de liberação de hormônios da glândula  $j$ ;

$x_i$  é a  $i$ -ésima entrada detectada pela glândula  $j$ ; e

$nx$  é o número total de entradas detectadas pela glândula  $j$ .

Dado que  $c_j(t)$  é a concentração de hormônio na glândula  $j$  no instante  $t$ , a variação desta concentração obedece a um decaimento geométrico:

$$c_j(t+1) = c_j(t) \times \beta \quad \text{Equação 6.2}$$

onde  $\beta \in (0,1)$  é uma constante de decréscimo do decaimento geométrico.

De forma geral, as glândulas liberam e mantêm um histórico da concentração de hormônios presentes no sistema de maneira a moderar a sua força de reação. Cada glândula libera um hormônio específico representado por um vetor binário. Cada hormônio possui associado a ele o seu nível de concentração. O nível de concentração de um hormônio afeta os

pesos de entrada da rede neural artificial. Considerando-se a existência de receptores hormonais específicos em cada neurônio artificial, o nível de concentração de um determinado hormônio presente no sistema afeta cada peso de entrada de um neurônio específico a ele (Equação 6.3).

$$u = \sum_{i=1}^{nx} w_i \left[ \prod_{j=1}^{ng} c_j S_{ij} M_{ij} \right] x_i \quad \text{Equação 6.3}$$

onde:

$u$  é a ativação interna ou entrada líquida do neurônio;

$w_i$  é o peso para uma determinada entrada  $x_i$ ;

$x_i$  é a  $i$ -ésima entrada para a rede neural;

$nx$  é o número total de entradas;

$ng$  é o número de glândulas do sistema;

$c_j$  é a concentração do hormônio  $j$ ;

$S_{ij}$  é a sensibilidade da conexão do receptor  $i$  com o hormônio  $j$ ; e

$M_{ij}$  mede a similaridade entre o receptor  $i$  e o hormônio  $j$ .

O trabalho de TIMMIS & NEAL (2004) carece de informações explícitas relacionadas à composição de alguns termos das equações acima, assim como de alguns detalhes de implementação. Entretanto, por ser um trabalho pioneiro e por haver apresentado resultados preliminares promissores (para maiores detalhes referir-se a NEAL & TIMMIS (2003) e TIMMIS & NEAL (2004)), esta tentativa de modelagem apresentou-se como uma motivação para a proposta a ser apresentada na próxima seção - um novo modelo para um sistema homeostático artificial.

Na realidade, anteriormente à primeira proposta de NEAL & TIMMIS (2003), VARGAS *et al.* (2001) já haviam teorizado sobre a possibilidade de uma investigação conjunta dos três sistemas biológicos: o sistema nervoso, o sistema imunológico e o sistema endócrino, todos compondo um único sistema cognitivo. O trabalho propôs também uma análise semiótica preliminar desses sistemas. Entretanto, o trabalho mencionado carece de maiores fundamentações e propostas práticas de implementações computacionais.

Nesta tese, por sua vez, entre outros objetivos a serem delineados na próxima seção,

procura-se propor um arquétipo mais biologicamente plausível do sistema endócrino artificial, como um passo adiante na criação de um sistema verdadeiramente *homeostático*.

Diversos pontos do trabalho de TIMMIS & NEAL (2004) são passíveis de discussão e, conseqüentemente, o novo modelo visa também propor melhorias e sanar alguns problemas possíveis detectados (as melhorias e propostas de solução delineadas a seguir serão explicitadas em mais detalhes na próxima seção). Por exemplo:

1) com relação à plausibilidade biológica do modelo, acredita-se que a utilização do mecanismo de armazenamento de hormônios em um reservatório foge parcialmente da inspiração biológica, na qual a maioria dos hormônios é produzida e liberada sob demanda (PURVES *et al.*, 2001). Especula-se que este aspecto da implementação computacional pode dificultar o controle do nível de concentração do hormônio no agente robótico. Desta forma, dota-se a nova proposta de mecanismos de retroalimentação positiva e negativa peculiares ao sistema endócrino para controlar automaticamente a secreção de hormônios.

2) observa-se que não existe uma ligação explícita entre a Equação 6.1 (produção de hormônio) e a Equação 6.2 (decaimento da concentração de hormônio). Como no item anterior, acredita-se que isto também pode ocasionar um descontrole em médio e longo prazo do nível hormonal no agente robótico, pois não há uma ‘comunicação’ entre os mecanismos de retroalimentação positiva e negativa de hormônios. No novo modelo, este problema é contornado com o emprego de equações a diferenças acopladas.

3) a interação do sistema endócrino artificial com a rede neural artificial é descrita pela Equação 6.3 e nota-se que o nível de concentração do hormônio age diretamente sobre os pesos de entrada dos neurônios na tentativa de controlar as saídas da rede. Acredita-se que um controle mais eficaz é implementado através da atuação do nível hormonal diretamente sobre as saídas da rede neural artificial, como será visto na seção 6.4.2.

Outra questão relevante refere-se à suposta composição do *sistema homeostático artificial*. Conjetura-se que o mesmo seria formado preferencialmente por uma rede neural artificial, um sistema endócrino artificial, e um sistema imunológico artificial. Esta divisão em módulos favorece o projeto e síntese de partes do sistema em separado. Por este motivo, vislumbrou-se a implementação, em um primeiro ensaio, somente da interação neuro-endócrina,

corroborando com a idéia inicial de TIMMIS & NEAL (2004). Vencida esta etapa, os próximos passos da pesquisa irão procurar encontrar o melhor modo de se incluir os SIA no processo, de forma a encurtar o caminho pela busca da homeostase em um agente artificial. Alternativas para inclusão do SIA aos demais módulos do sistema serão sugeridas no Capítulo 7.

### **6.3. Sistema Homeostático Artificial: Uma Nova Proposta**

O novo sistema homeostático artificial a ser proposto nesta seção é composto por duas redes neurais artificiais e um sistema endócrino artificial e será empregado mais adiante, ainda neste capítulo, para controlar as ações de um agente robótico artificial. Cada rede neural artificial é treinada para tarefas distintas e exclusivas. Portanto, o papel do sistema endócrino artificial é coordenar as ações dessas redes neurais artificiais.

Discorre-se, na próxima seção, sobre o projeto das redes neurais artificiais. Na Seção 6.3.2, introduz-se o novo projeto do sistema endócrino artificial. Em seguida, na Seção 6.3.3, descrevem-se detalhes da *interação* do sistema endócrino artificial com as redes neurais artificiais, a qual determina a dinâmica do novo sistema homeostático artificial.

#### **6.3.1 Projeto das Redes Neurais Artificiais**

As redes neurais artificiais deste novo modelo, como no trabalho anterior de TIMMIS & NEAL (2004), são redes de múltiplas camadas tipo MLP com funções de ativação do tipo sigmoideal. Para treiná-las, emprega-se o algoritmo de aprendizagem por retropropagação (HAYKIN, 1999).

Conforme mencionado anteriormente, cada rede é treinada para desempenhar uma tarefa distinta e exclusiva. Convém ressaltar que os neurônios artificiais diferem da proposta anterior, pois não possuem receptores específicos para hormônios. Isto se deve ao fato de, neste novo modelo, o sistema endócrino artificial atuar diretamente na saída das redes neurais artificiais, através do valor do nível hormonal. Portanto, não existe interação direta dos hormônios com os neurônios. Maiores detalhes relacionados às dimensões da rede e formas de obtenção de dados para o treinamento serão abordados na Seção 6.4.2.

### 6.3.2 Projeto do Sistema Endócrino Artificial

A idéia principal no desenvolvimento do novo modelo de sistema endócrino artificial está na tentativa de reprodução de alguns mecanismos de retroalimentação positiva e negativa presentes no sistema endócrino da espécie humana (Seção 6.1). Recorda-se que estes mecanismos são utilizados, na maioria das vezes, para controlar o nível de concentração hormonal dentro do organismo. Na realidade, a concentração de determinados hormônios *rege* o comportamento do organismo, seja pela definição do consumo de determinada substância, ou pelo estabelecimento de novos pontos de operação de órgãos e sistemas, por exemplo, via a alteração da temperatura corporal. Desta forma, acredita-se que, com a implementação computacional destes mecanismos reguladores em sintonia com outros mecanismos adaptativos, abrem-se novas perspectivas para a promoção de homeostase artificial.

Levando-se em conta que sistemas homeostáticos são concebidos de modo a expressar robustez frente a variações em seu ambiente interno e a estímulos externos, é certo que outras propostas capazes de atender este objetivo seriam igualmente válidas, mesmo que não inspiradas em controles homeostáticos naturais. Como exemplo, podemos citar as já seculares estratégias de controle de processos em engenharia dedicadas à rejeição de perturbação (de origem interna ou externa) em malhas de controle, pelo projeto de filtros dotados de comportamento de entrada-saída adequados (OGATA, 2001).

De partida, dois conceitos são essenciais para o entendimento do novo modelo de sistema endócrino artificial e da dinâmica do sistema. Estes conceitos são: o *estado interno* do agente artificial e os *estímulos externos* aos quais ele está exposto. A Tabela 6.1 exemplifica possíveis tipos de *estado interno* e de *estímulo externo*, provendo algumas analogias entre robôs e organismos biológicos.

**Tabela 6.1 Exemplos de estado interno e de estímulo externo, incluindo algumas analogias entre robôs e organismos biológicos.**

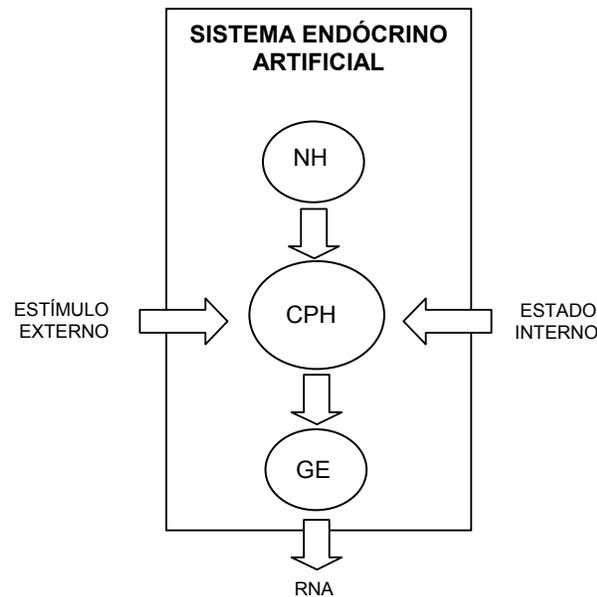
Tipo	Definição	Robô	Organismo
Estado Interno	Necessidade, desejo	Nível de energia. Qual é o nível interno da bateria?	Fome, sede. Qual é a extensão da fome?
Estímulo Externo	Estímulo recebido do ambiente	Qual é a distância até a base de recarga?	Quanto alimento existe, ou quão longe está a fonte de alimento?

Conforme ilustrado na Tabela 6.1, a associação dos conceitos de estado interno e estímulo externo de um agente artificial com os de um organismo biológico é bem intuitiva. O estado interno de um agente artificial (ou um robô) simboliza o nível de determinada necessidade, por exemplo, uma necessidade de recarga que, por sua vez, pode depender do valor da energia interna do robô. Se a energia interna está alta, a necessidade de recarga é pequena. Conforme a energia interna cai, a necessidade de recarga aumenta. Os estímulos que o agente artificial recebe do ambiente caracterizam os estímulos externos: por exemplo, a localização de uma base para recarga.

De posse dos conceitos de estado interno e estímulo externo, descreve-se a seguir os módulos que compõem o novo sistema endócrino artificial. Diferentemente da proposta anterior de TIMMIS & NEAL (2004), a nova proposta é composta por três módulos, criados para promover um controle homeostático artificial (Figura 6.5):

- 1 – Módulo nível hormonal (NH);
- 2 – Módulo controlador de produção de hormônios (CPH); e
- 3 – Módulo glândula endócrina (GE).

O módulo nível hormonal (NH) possui um registro do nível de cada hormônio dentro do agente artificial; o módulo controlador de produção de hormônio (CPH) é responsável por controlar a produção de hormônio em resposta a variações internas (nível hormonal e *estado interno*) e externas (*estímulo externo*); e o módulo glândula endócrina (GE) recebe sinais do CPH, sendo responsável por produzir e liberar hormônios quando necessário, os quais irão atuar nas saídas das redes neurais artificiais (RNA).



**Figura 6.5 – Visão geral dos principais componentes da nova proposta para um sistema endócrino artificial e suas interações externas e internas (com o próprio agente artificial e com as RNA). NH: nível hormonal; CPH: controlador de produção de hormônios; GE: glândula endócrina; e RNA: redes neurais artificiais.**

Entre os componentes do novo sistema endócrino artificial, o controlador de produção de hormônios é o único que se comunica diretamente com o ambiente interno e externo. Como será detalhado na próxima seção, o CPH desempenha um papel central no desenvolvimento do sistema homeostático artificial.

### 6.3.3 Dinâmica do Sistema

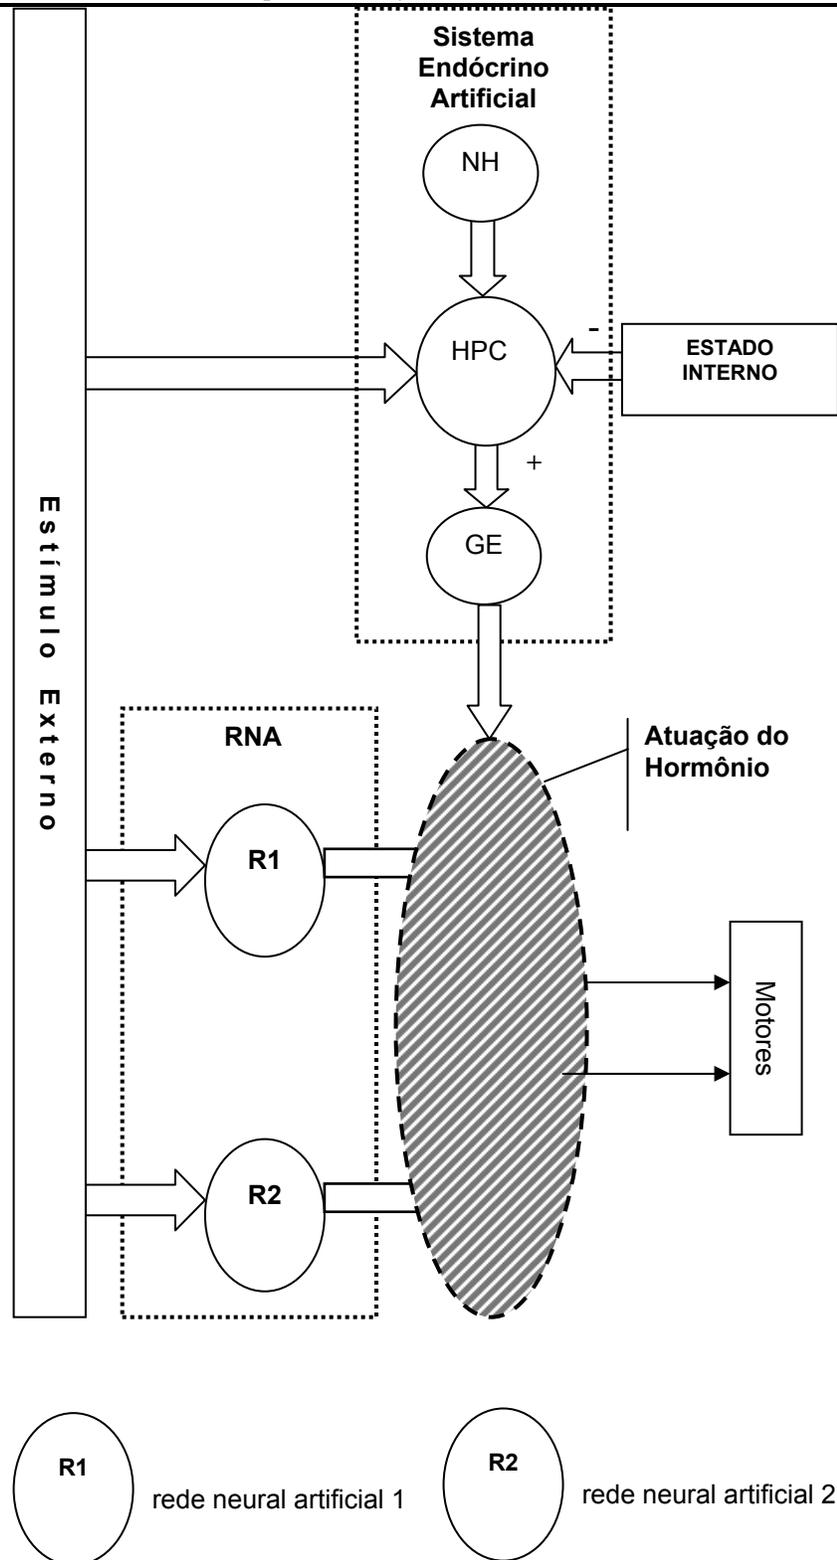
Em linhas gerais, a dinâmica do sistema baseia-se nos principais mecanismos de homeostase, particularmente os mecanismos de retroalimentação positiva e negativa do sistema endócrino. O módulo de controle de produção de hormônios (CPH) percebe alterações específicas no *estado interno* e no ambiente externo (*estímulo externo*), e envia sinais excitatórios para a glândula endócrina. A GE começa a produzir e a liberar hormônios, aumentando assim o nível hormonal. O nível hormonal altera o *estado interno*, pois produz efeitos nas saídas das redes neurais artificiais, as quais, no caso de estudo a ser apresentado

neste capítulo (Seção 6.4), irão determinar as ações de um agente robótico sobre o ambiente.

A Figura 6.6 ilustra (em grandes linhas) as interações do sistema endócrino artificial com as RNA e dos mesmos com o ambiente (*estímulo externo*) e com o agente artificial. Nesta figura, antecipa-se que as saídas das RNA irão determinar a velocidade empregada nos *motores* que governam as rodas do agente robótico.

O módulo CPH continua estimulando a GE a produzir hormônios até que ele experimente sinais inibitórios (retroalimentação negativa) provenientes do *estado interno*. Neste instante, o módulo CPH cessa a produção de sinais excitatórios até que ele perceba novas alterações específicas no *estado interno* (retroalimentação positiva). Os hormônios produzidos pela GE irão atuar nas saídas das RNA. O mecanismo completo de atuação dos hormônios nas saídas das redes será exposto na Seção 6.4.2, onde se inicia a descrição dos experimentos com o agente robótico.

Nesta tese, o estado interno (EI) simboliza a necessidade de recarga do agente artificial. Conforme esta necessidade aumenta, a dinâmica do sistema determina que o robô passe a apresentar um comportamento de “busca” pela base para recarga. Em robótica autônoma, pode-se considerar a base como um alvo a ser perseguido. Fazendo-se uma analogia com as necessidades e desejos do ser humano, o alvo pode ser determinado por vários tipos de comportamentos. Por exemplo, se a necessidade é de “se alimentar”, então o alvo é a “fonte de alimento”.



**Figura 6.6 – Interação do sistema endócrino artificial com as redes neurais artificiais, com o agente artificial e com o ambiente.**

O valor do estado interno depende do nível de estímulo externo (EE) do ambiente e do nível hormonal (NH) do agente, no instante  $t$  (Regra 6.1). Se o EE e o NH estão acima de valores limites predeterminados ( $\lambda$  e  $\omega$ , respectivamente), então o EI é nulo, ou seja, o nível da “necessidade” cessa. Isto ocorre porque existe suficiente estímulo externo e hormônio para desencadear o comportamento associado ao estado interno. Caso contrário, o EI cresce a uma taxa  $\beta$  predeterminada até atingir um valor máximo, também predeterminado,  $\text{Max}(\text{EI})$ :

$$\begin{aligned} &\text{Se } (EE \geq \lambda) \text{ e } (NH \geq \omega) \\ &\text{então } EI = 0, \\ &\text{senão } EI(t+1) = EI(t) + \beta(\text{Max}(\text{EI}) - EI(t)). \end{aligned} \qquad \text{Regra 6.1}$$

O estímulo externo (EE) depende da proximidade do agente artificial ao alvo. Analogamente à sensibilidade do corpo humano a estímulos externos, esta distância pode ser medida pelo agente artificial utilizando seus sensores. Esta informação está disponível tanto para as redes neurais artificiais quanto para o sistema endócrino artificial.

O CPH procura reproduzir aspectos do funcionamento do hipotálamo no cérebro humano e, desta forma, recebe sinais tanto do ambiente externo (estímulo externo) quanto do ambiente interno (nível hormonal e estado interno) e, de acordo com situações específicas, pode estimular a produção e conseqüente liberação de hormônios através da glândula endócrina (GE). Este disparo aumenta a concentração de hormônios levando ao estímulo na saída das redes neurais, e o conseqüente desencadeamento de alguma tarefa. Este processo ocorre pela priorização da resposta de uma das redes dependendo do nível de concentração de hormônio. Esta priorização é necessária, pois está se tratando de redes que são treinadas para tarefas distintas e, portanto, é essencial a existência de uma coordenação da manifestação dessas tarefas. Enquanto a tarefa não é executada, o CPH continua a estimular a produção e liberação de hormônios. Desta forma, mantém-se um nível hormonal adequado para continuar estimulando a execução da tarefa. Assim que a tarefa é realizada, ou seja, assim que o CPH recebe o sinal de retroalimentação negativa, ele cessa o estímulo à produção e liberação de hormônios. Com base neste mecanismo, a Regra 6.2 ilustra o controle de produção e liberação de hormônios pelo módulo CPH:

$$\begin{aligned} &\text{Se } EI \geq \theta \\ &\text{então } HP(t+1) = (100 - \%EE) \times \alpha (\text{Max}(\text{NH}) - \text{NH}(t)), \\ &\text{senão } HP = 0. \end{aligned} \quad \text{Regra 6.2}$$

onde:

$\theta$  é o limite alvo do estado interno (EI);

HP é a produção de hormônio<sup>‡‡</sup>;

%EE é o estímulo externo percentual;

$\alpha$  é o fator de escala;

Max(NH) é o máximo nível hormonal; e

$t$  é o índice do tempo.

Se o estado interno (EI) é maior ou igual ao limite alvo  $\theta$ , então o hormônio será produzido em uma escala que dependerá do nível de estímulo externo e do nível hormonal no agente. Caso contrário, se o estado interno é menor do que o limite alvo  $\theta$ , então cessa-se a produção de hormônio.

O nível hormonal representa a quantidade de hormônio que está estimulando as redes neurais artificiais. O nível hormonal irá sofrer alterações constantes em seu valor devido à sua *taxa de meia-vida* (GUYTON & HALL, 1996), a qual normalmente é calculada por uma exponencial, e à quantidade de hormônio produzida:

$$\text{NH}(t+1) = \text{NH}(t) \times e^{-1/T} + \text{HP}(t) \quad \text{Equação 6.4}$$

onde  $T$  é a medida da meia-vida do hormônio.

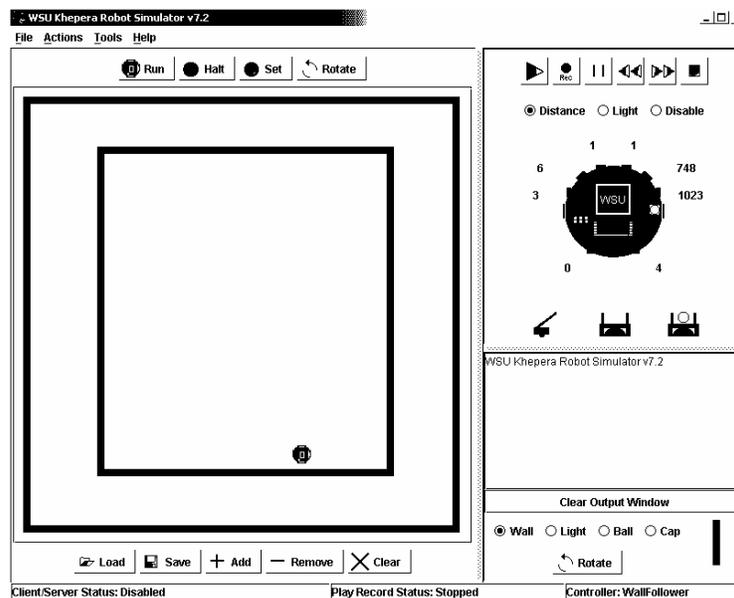
Descrevem-se a seguir experimentos virtuais (sem ambiente de navegação), simulados (com ambiente de navegação virtual) e práticos (com ambiente de navegação real) na tentativa de se avaliar o comportamento da nova proposta de sistema homeostático artificial no contexto de problemas de navegação autônoma de robôs.

<sup>‡‡</sup> Utilizou-se o símbolo HP (do inglês “*Hormone Production*”) ao invés do PH, para não se confundir com o símbolo pH que se refere à acidez de uma solução.

## 6.4. Aplicação: Robótica Autônoma

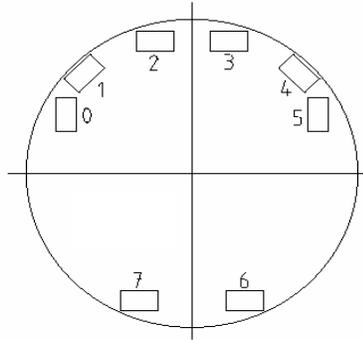
No desenvolvimento do novo sistema homeostático artificial, a proposta desta tese adota algumas idéias de inteligência incorporada, formuladas por Rodney Brooks (BROOKS, 1991a; BROOKS, 1991b). O objetivo é sintetizar um sistema de navegação autônomo com base em estado interno, dinâmicas acopladas e estímulo (ou excitação) externa.

Com o intuito de se avaliar a performance do novo sistema endócrino artificial, conduzem-se quatro experimentos. O **Experimento I** utiliza um cenário artificial, sem recorrer diretamente a um agente robótico. Nos **Experimentos II e III**, aplicam-se as idéias de inteligência incorporada em um agente robótico *simulado*, utilizando-se o simulador WSU Khepera Simulator (PERRETTA & GALLAGHER, 2003) (Figura 6.7). No **Experimento IV**, essas idéias são empregadas em um agente robótico *real*, utilizando-se o Khepera II (Figura 6.9).



**Figura 6.7** – O simulador WSU ilustrando a arena (à esquerda) com o robô Khepera seguindo paralelamente a uma parede, juntamente com a leitura de seus 8 sensores de distância (à direita).

O robô Khepera II tem aproximadamente 7cm de diâmetro e desloca-se a 0,5cm a cada passo. Ele possui oito sensores infravermelhos, sendo que seis sensores estão localizados na parte frontal e dois sensores estão localizados na parte traseira (veja Figura 6.8).



**Figura 6.8 – Disposição dos oito sensores infravermelhos no robô Khepera II. Seis sensores na parte frontal e dois sensores na parte traseira.**

A escolha do robô Khepera II (Figura 6.9), no desenvolver dos experimentos com agentes robóticos simulados e reais, justifica-se por ser um robô amplamente aceito e divulgado na comunidade científica. Estes robôs são produzidos pela empresa K-Team (Suíça) (K-TEAM S.A., 2005) e a sua disseminação propiciou comparações de desempenho entre experimentos realizados por grupos de pesquisa distintos, o que era praticamente impossível anteriormente. Este fato corroborou para ampliar o número e a qualidade das pesquisas com inteligência incorporada, na qual é essencial a busca pela padronização dos experimentos (DORIGO & COLOMBETTI, 1997; NOLFI & FLOREANO, 2000).



**Figura 6.9 – O robô Khepera® Geração II comparado em dimensão a uma moeda de €2,00 (2 euros) (o tamanho de uma moeda de €2,00 equivale ao de uma moeda de R\$1,00).**

O simulador ilustrado na Figura 6.7 foi desenvolvido na Wright State University com a finalidade de prover uma plataforma para o desenvolvimento de controladores anterior à aplicação no robô real Khepera II® (K-TEAM S.A., 2005). Este simulador é composto

basicamente por:

- 1) uma arena reconfigurável à esquerda, que pode ser composta por paredes, pontos de fonte de luz e objetos circulares;
- 2) um painel de controle das simulações na parte de cima da arena;
- 3) uma imagem do robô à direita, juntamente com a leitura dos sensores de distância e de luz;
- 4) um painel de controle da gravação das simulações acima da imagem do robô e;
- 5) uma barra de status na parte inferior do simulador, que identifica qual controlador está sendo executado.

Existem sensores de distância e de luz. Os sensores de distância simulam os sensores infravermelhos do robô real (total de 8 (oito) sensores) (Figura 6.8) e detectam obstáculos (que podem ser paredes, pontos de fonte de luz ou objetos circulares). A leitura de um sensor de distância pode variar entre os valores de 0 a 1023 unidades, sendo que o valor 1023 representa proximidade máxima ao obstáculo. Como exemplo, veja a leitura dos sensores de distância ilustrada no lado direito da Figura 6.7, onde o robô segue paralelamente a uma parede.

De modo análogo, os sensores de luz simulam os sensores infravermelhos do robô real e detectam a presença de pontos de fonte de luz no ambiente. A leitura de um sensor de luz pode variar de 50 a 500. Sendo que o valor 50 representa máxima luminosidade.

Com relação aos oito sensores infravermelhos, é importante ressaltar que o robô Khepera II real utiliza os mesmos oito sensores infravermelhos para detectar tanto a distância a obstáculos quanto a presença de luz no ambiente. Esta característica dificulta o trabalho com o robô real, caso se queira utilizar as duas leituras em paralelo. Isto ocorre como consequência de que a presença de uma fonte de luz próxima ao robô satura os sensores infravermelhos, de forma que a leitura da distância a obstáculos é afetada, dando a impressão que o robô está rodeado por obstáculos. Mais detalhes sobre este problema e soluções paliativas serão discutidos na Seção 6.4.4.

Este problema não ocorre na simulação, pois o ambiente do WSU Khepera Simulator separa a leitura dos dois tipos de sensores (obstáculo e luz). Dessa maneira, a leitura de um tipo de sensor não interfere na leitura do outro.

O motivo da escolha deste ambiente particular de simulação justifica-se pela plataforma de desenvolvimento em uma das melhores linguagens de programação atualmente disponíveis (Linguagem JAVA™) e pela maior facilidade de transição da aplicação do sistema de controle do ambiente simulado para o ambiente real. De fato, observa-se que os seus criadores preocuparam-se em desenvolver uma ferramenta que reduzisse o impacto deste processo de transição da simulação para o robô real. Por este motivo, tanto os sensores de distância quanto os de luz simulam altos níveis de ruído. Isto se verifica durante a simulação quando posições do robô na arena, muito próximas uma da outra, revelam alterações drásticas na leitura dos sensores, reproduzindo com algum grau de equivalência o que ocorre no ambiente real.

A razão por trás do **Experimento I** está em regular a interação do sistema com um ambiente virtual sem a utilização explícita de um agente robótico simulado ou real. Já com os **Experimentos II e III** (agente robótico *simulado*) procura-se primeiro mostrar a adaptabilidade do sistema através de sua habilidade para lidar com mudanças internas e externas; e, segundo, atestar a habilidade do sistema em se adaptar a um ambiente dinâmico, apresentando o fenômeno biológico de comportamento cíclico sincronizado ao montante de recursos disponíveis através de um controle homeostático.

O **Experimento IV** (agente robótico *real*) serve ao propósito de avaliar o desempenho do mesmo sistema homeostático artificial (empregado no **Experimento II**) aplicado a um robô real, promovendo basicamente a oportunidade de uma análise prática das possíveis diferenças de comportamento entre simulação e experimento real.

### 6.4.1 Experimento I

Conforme mencionado anteriormente, o **Experimento I** é projetado utilizando-se um cenário artificial e seu principal objetivo está em regular a interação do sistema com um ambiente virtual, sem a utilização explícita de um agente robótico simulado ou real. Este experimento envolve a criação de uma função randomicamente variável em torno de uma curva senoidal para simular a presença de um estímulo externo (EE) oscilatório (VARGAS *et al.*, 2004). Adota-se uma curva com estas características oscilatórias fazendo-se alusão à disponibilidade

cíclica de recursos em um ambiente ao longo do tempo. O tempo neste experimento é retratado por uma variável que simboliza o decorrer do tempo em segundos.

Para que este experimento inicial sirva de base para os próximos experimentos, todos os parâmetros que compõem as regras e equações do novo sistema homeostático artificial (Seção 6.3) são testados e ajustados durante este experimento. Deste modo, define-se empiricamente que o estímulo externo (EE) é representado por uma função randomicamente variável em torno de uma curva senoidal que apresenta valores no intervalo  $[0,1]$ , e o nível hormonal (NH) e o estado interno (EI) variam no intervalo  $[0,100]$ .

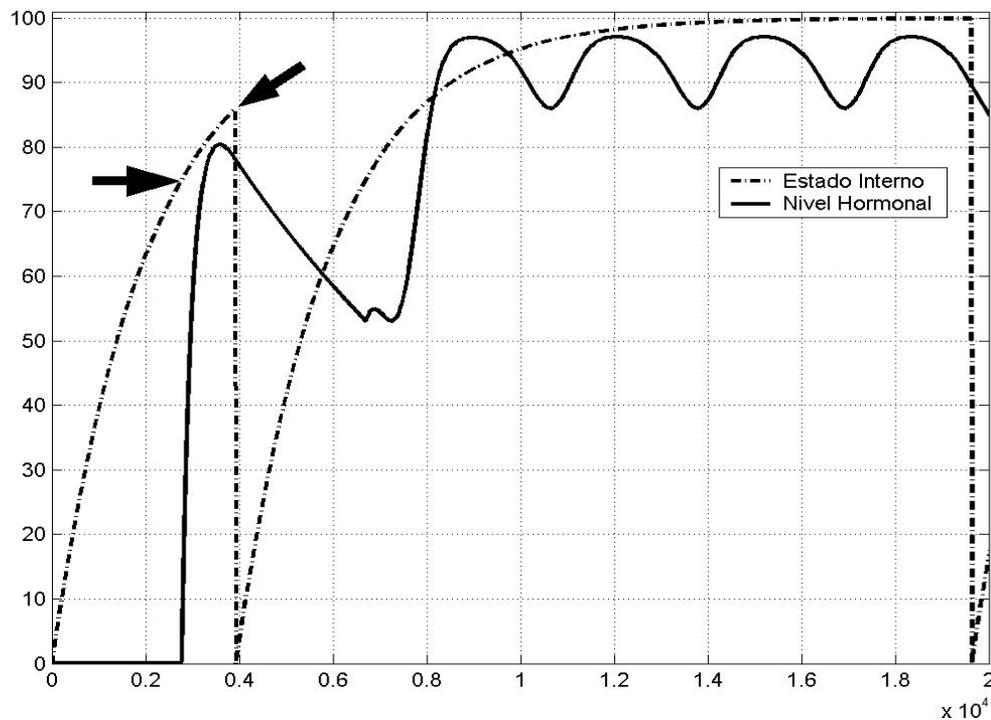
Com relação à Regra 6.1, Seção 6.3.3, recorda-se que os parâmetros  $\lambda$  e  $\omega$  representam respectivamente os valores mínimos que o EE e o NH precisam atingir para tornar nulo (ou reduzir a zero) o EI. Como o EI nesta tese representa uma necessidade de recarga, o fato de o EI tornar-se nulo deve ocorrer quando o agente robótico atinge o seu alvo, que está relacionado com a sua necessidade. Por exemplo, se a necessidade é de recarga, o alvo é a base ou fonte de energia. Portanto, como o EE apresenta valores no intervalo  $[0,1]$ , adotou-se o valor 0,994 para o parâmetro  $\lambda$ , representando a máxima proximidade do robô ao alvo e 70 para o NH. O parâmetro  $\beta$  representa uma constante fixa que rege a taxa de crescimento do EI e, para este experimento,  $\beta = 0,0005$ . Resumindo, para a Regra 6.1, os parâmetros ajustados empiricamente são:  $\lambda = 0,994$ ;  $\omega = 70$  e  $\beta = 0,0005$ .

Com relação à Regra 6.2, Seção 6.3.3, adotou-se o valor 75 para  $\theta$ , representando o valor mínimo que o EI precisa atingir para disparar a produção de hormônio (HP). Recorda-se que, uma vez iniciada a produção de hormônio, o HP irá variar dependendo de duas grandezas: da proximidade ao alvo, determinada pelo valor do EE, e do NH multiplicado por uma taxa  $\alpha$ , que neste experimento assume o valor 0,005. Resumindo, para a Regra 6.2, os valores adotados para os parâmetros são:  $\theta = 75$ ,  $\alpha = 0,005$ .

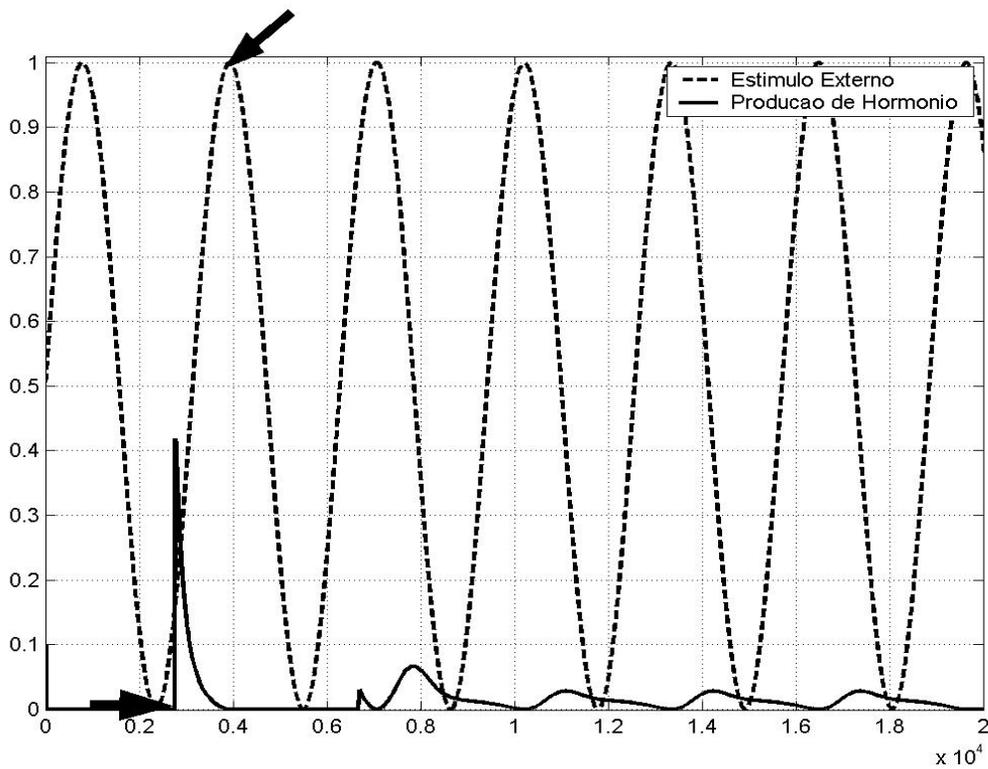
O único parâmetro associado à Equação 6.4, Seção 6.3.3, é o parâmetro  $T$  que compõe a taxa de meia-vida do hormônio. Recorda-se que o NH irá sofrer alterações constantes em seu valor devido à taxa de meia-vida e à quantidade de hormônio produzida (HP). Adotou-se  $T = 7.200$ .

Este cenário artificial serve ao propósito inicial de facilitar a sintonia dos parâmetros do sistema através do emprego de constantes de tempo adequadas a este experimento. Para ilustrar o **Experimento I**, prepara-se uma simulação que permite ilustrar a dependência do nível de estado interno com o nível hormonal (Figura 6.10 (a)) e a reação do sistema à presença de um estímulo externo virtual (Figura 6.10 (b)), durante 20.000 instantes amostrais de tempo (aqui relacionado a segundos).

O comportamento foi medido em termos de nível de estado interno (EI) e nível hormonal (NH). Observa-se, na Figura 6.10 (a) que, no instante  $t = 0$ , o EI é nulo e, portanto, a produção de hormônio não é estimulada (a produção só é estimulada se o EI atingir um valor limite predefinido:  $\theta = 75$ ). O estado interno depende do nível de estímulo externo (EE) e do nível hormonal (NH) (Seção 6.3.3, Regra 6.1) presentes no organismo artificial no instante  $t$ . Desta forma, a partir do instante  $t > 0$ , o estado interno começa a crescer a uma taxa  $\beta = 0,0005$  até que o mesmo atinge o nível  $\theta = 75$  e inicia-se a produção de hormônio (instante assinalado por setas horizontais à esquerda nas Figura 6.10 (a) e (b)).



(a)



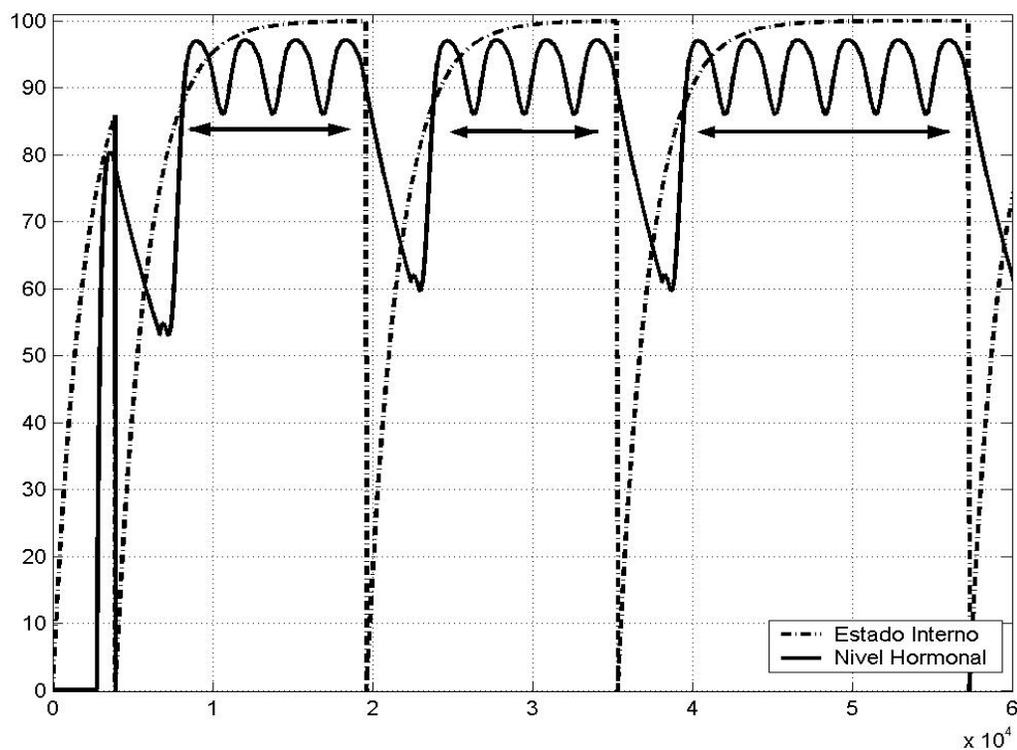
(b)

**Figura 6.10 — Experimento I: (a) comparação do desempenho do sistema em termos de nível de estado interno (EI) e nível hormonal (NH); (b) nível de estímulo externo (EE) e da produção de hormônio (HP) durante os primeiros 20.000 instantes amostrais de tempo. O eixo das abscissas representa a escala do tempo, o eixo das ordenadas representa o valor do nível das variáveis de 0 a 100 unidades (a) e de 0 a 1 unidade (b).**

Neste momento, o NH começa a aumentar até atingir um valor acima do limite  $\omega = 70$ , no qual o EE também atinge o valor  $\lambda = 0,994$  (Figura 6.10 (b)). Nesta ocasião, em torno do instante  $t = 4.000$ , o EI torna-se nulo (reduz-se para zero) (instante assinalado por uma seta inclinada à direita na Figura 6.10 (a)). Este comportamento indica que houve suficiente estímulo externo ( $EE = 0,994$ ; instante assinalado por uma seta inclinada à direita na Figura 6.10 (b)) e nível hormonal para estimular o comportamento de busca. Portanto, o agente robótico teria conseguido atingir seu alvo.

Ilustra-se, a seguir, o desempenho do mesmo sistema durante 60.000 instantes amostrais de tempo (Figura 6.11). Apesar de tratar-se de uma simulação desenvolvida para um ambiente virtual, foi possível ajustar os parâmetros e inclusive observar aspectos interessantes ao longo

do tempo. Por exemplo, observa-se na Figura 6.11 que o NH mantém-se em valores altos enquanto o sistema não atinge seu objetivo (instantes assinalados por três setas horizontais de duplo sentido). Este é exatamente o papel que se espera do nível hormonal, ou seja, que ele continue estimulando o agente robótico a buscar o alvo (base de recarga ou fonte de energia) até alcançá-lo, satisfazendo sua necessidade de recarga. É oportuno igualmente ressaltar, que a meia-vida do hormônio justifica o comportamento oscilatório de baixa amplitude que o NH apresenta quando em altas concentrações.



**Figura 6.11 - Experimento I: desempenho do sistema em termos de nível do estado interno (EI) e nível hormonal (NH) durante 60.000 instantes amostrais de tempo. O eixo das abscissas representa a escala do tempo e o eixo das ordenadas representa o valor do nível das variáveis de 0 a 100 unidades.**

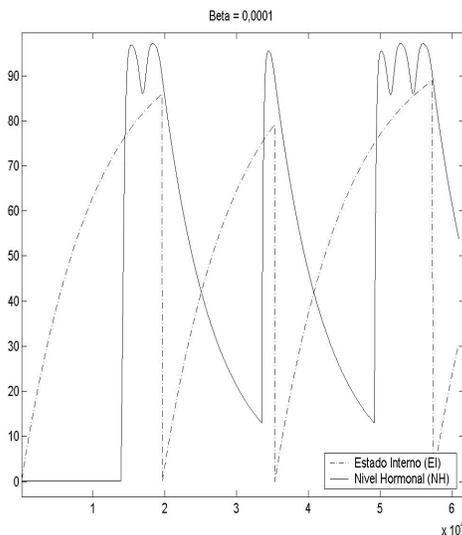
A seguir, apresentam-se na Figura 6.12 e Figura 6.13 estudos relativos à influência dos parâmetros  $\beta$  da Regra 6.1 e  $\alpha$  da Regra 6.2, respectivamente, no estado interno e no nível hormonal. Para os dois parâmetros, o estudo foi conduzido com variações relativas aos valores adotados no **Experimento I** ( $\beta = 0,0005$  e  $\alpha = 0,005$ ) e para duas condições iniciais distintas.

As condições iniciais distinguem-se pela sensibilidade do sistema às variações do estímulo externo, condição inicial I – menos sensível, condição inicial II – mais sensível.

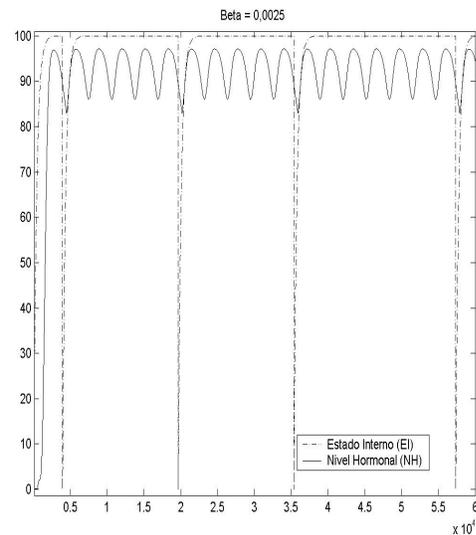
Para valores mais baixos do parâmetro  $\beta$ , como  $\beta = 0,0001$ , a ser adotado nos **Experimentos II e III** (Seções 6.4.2 e 6.4.3), o estado interno cresce mais lentamente, não chegando à saturação durante o intervalo de tempo adotado. Isto causa uma maior variação no nível hormonal (Figura 6.12 (a) e (c)).

Para valores mais altos ( $\beta = 0,0025$ ) o estado interno cresce muito rápido, chegando à saturação várias vezes no intervalo de tempo adotado. Isto mantém o nível hormonal em faixas de alta concentração (Figura 6.12 (b) e (d)).

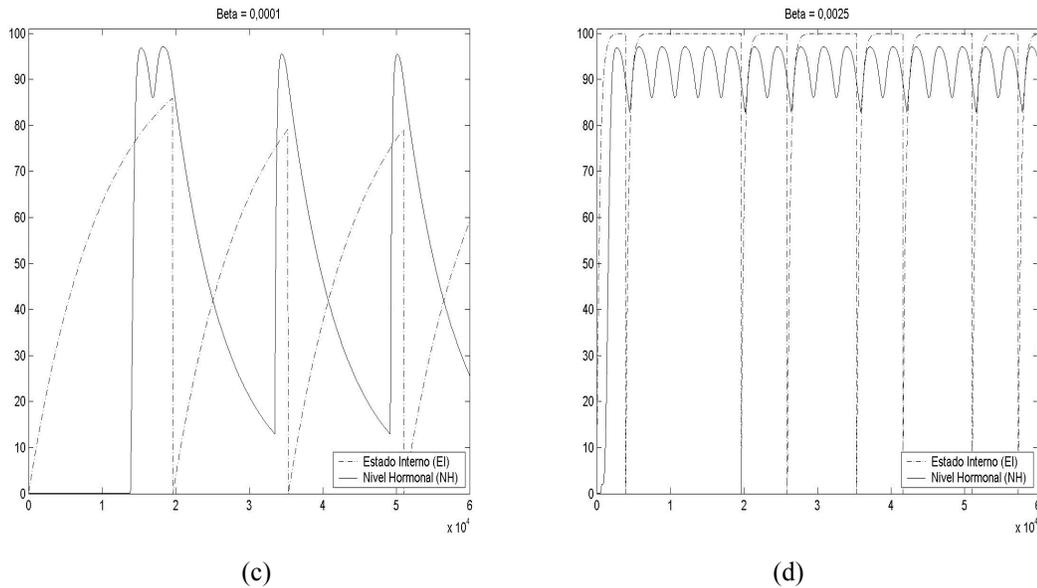
A diferença nas condições iniciais alteraram significativamente o comportamento para a simulação com  $\beta = 0,0025$  (Figura 6.12 (b) e (d)), ilustrado pela quantidade de vezes em que o estado interno atingiu o nível mínimo (EI = 0). Isto ocorreu em consequência da sensibilidade ao estímulo externo para a condição inicial I (Figura 6.12 (d)) ser maior do que para a condição inicial II (Figura 6.12 (b)), aliado ao crescimento acelerado do EI. Isso significa que, com o sistema mais sensível ao estímulo externo e o estado interno crescendo rapidamente, o nível hormonal mantém-se alto e cada aproximação mínima ao alvo é o suficiente para se considerar que o objetivo foi alcançado, tornando o EI nulo (EI = 0).



(a)



(b)

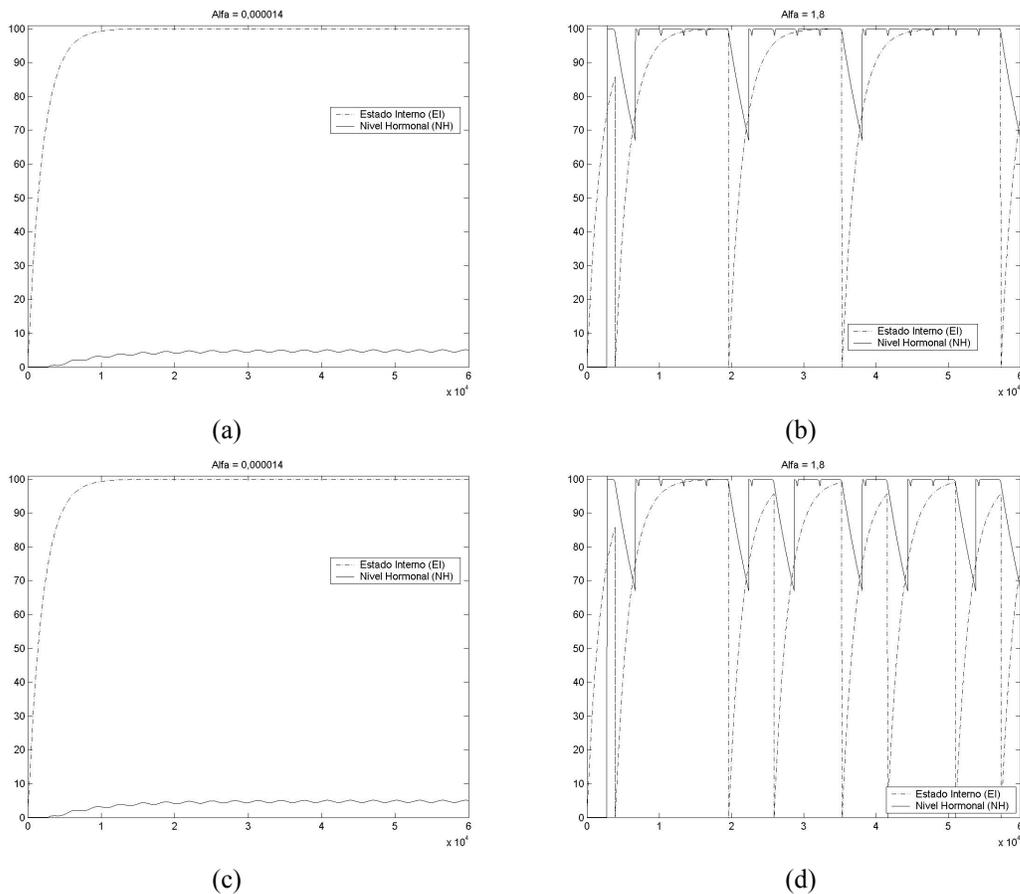


**Figura 6.12 – Estudo da influência da variação do parâmetro  $\beta$  para dois valores e para duas condições iniciais distintas durante 60.000 instantes amostrais de tempo. Figuras (a) e (b), condição inicial I e figuras (c) e (d), condição inicial II.**

O parâmetro  $\alpha$  influencia a produção de hormônios e conseqüentemente altera diretamente o nível hormonal. A Figura 6.13 ilustra o comportamento do estado interno e do nível hormonal para dois valores de  $\alpha$  e duas condições iniciais.

Observa-se que, para valores mais baixos do parâmetro  $\alpha$ , o nível hormonal cresce muito lentamente e chega a apresentar um nível médio muito baixo e praticamente constante ao longo do tempo (Figura 6.13 (a) e (c)). Isto causa uma saturação no estado interno (EI = 100), pois o nível hormonal não atinge um valor satisfatório para disparar o comportamento desejado.

Para valores mais altos, como  $\alpha = 1,8$ , a ser adotado nos **Experimentos II e III** (Seções 6.4.2 e 6.4.3), a produção de hormônios é alta, fazendo o nível de hormônio atingir rapidamente a saturação várias vezes no intervalo de tempo adotado, mantendo o nível hormonal em faixas de alta concentração.



**Figura 6.13– Estudo da influência da variação do parâmetro  $\alpha$  para dois valores e para duas condições iniciais distintas durante 60.000 instantes amostrais de tempo. Figuras (a) e (b), condição inicial I e figuras (c) e (d), condição inicial II.**

A diferença nas condições iniciais produziu o mesmo comportamento observado nas Figura 6.12 (b) e (d), alterando a quantidade de vezes em que o estado interno atingiu o nível mais baixo (EI = 0) (Figura 6.13 (b) e (d)). Isto comprova que o EI depende da sensibilidade ao estímulo externo, representado na Figura 6.13 (d), e do NH.

## 6.4.2 Experimento II

O objetivo deste experimento é verificar o desempenho do novo sistema homeostático artificial no controle da navegação de um agente robótico *simulado*. Procura-se alcançar este

objetivo pela observação da adaptabilidade do sistema através de sua habilidade em lidar com mudanças internas e externas.

Os parâmetros adotados foram:  $\beta = 0,0001$ ;  $\alpha = 1,8$ ;  $T = 500$ ;  $\lambda = 150$ ;  $\omega = 75$ ; e  $\theta = 75$ . Estes valores diferenciam-se dos valores empregados no **Experimento I** em consequência da adequação dos parâmetros ao **Experimento II**, que simula o comportamento de um robô real. Além disso, o **Experimento I** foi desenvolvido em um outro momento da pesquisa, onde ainda não havia a presença do agente robótico simulado<sup>§§</sup>.

Este segundo experimento é destinado a um agente robótico simulado utilizando o simulador WSU Khepera Robot Simulator (PERRETTA & GALLAGHER, 2003) (Figura 6.7). Neste experimento, o robô aprende primeiramente duas tarefas distintas: seguir paredes evitando colisões e detectar uma fonte de luz (associada aqui a uma fonte de energia). Ambas as tarefas foram aprendidas através do emprego do algoritmo de aprendizagem por retropropagação (HAYKIN, 1999) para treinar separadamente duas redes neurais de múltiplas camadas tipo MLP (“*multi-layer perceptron*”, na literatura em inglês) via dados amostrados. Estes dados foram coletados via amostras de posições predeterminadas do robô na arena, as quais representavam situações de navegação relevantes. As redes possuem seis entradas (fazendo-se referência aos seis sensores frontais do agente robótico) (Figura 6.8), dezesseis neurônios na camada intermediária e duas saídas de controle (uma para cada roda do agente robótico).

Diferentemente do mecanismo adotado por TIMMIS & NEAL (2004), neste trabalho o sistema endócrino artificial irá coordenar as duas redes neurais artificiais modulares através da atuação do nível de concentração de hormônio diretamente na saída das redes. O mecanismo completo está ilustrado na Figura 6.14, que esboça detalhes da interação do sistema endócrino artificial com as redes neurais artificiais, com ênfase no mecanismo adotado para governar a coordenação do sistema endócrino artificial junto às RNA através do nível hormonal.

---

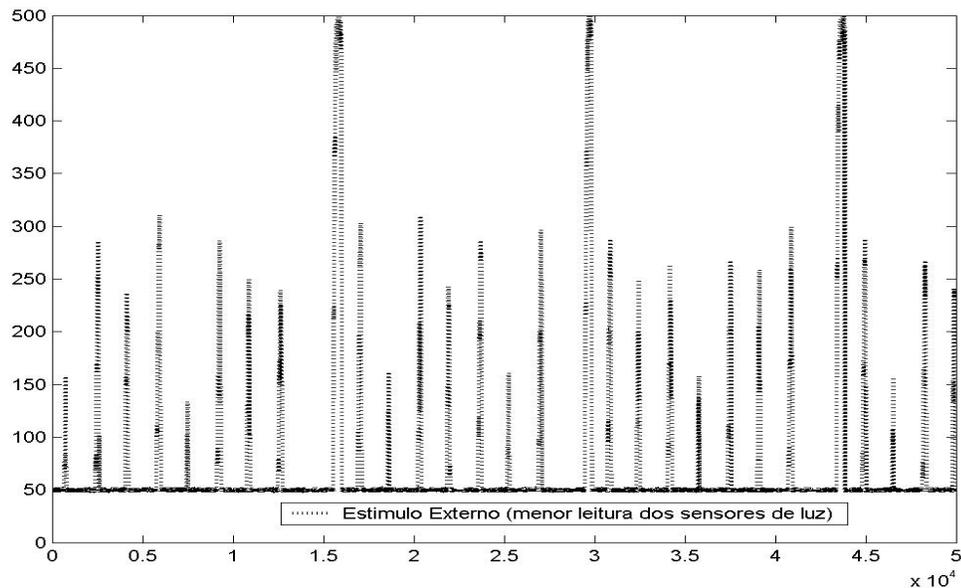
<sup>§§</sup> O **Experimento I** foi desenvolvido durante uma visita técnica em fevereiro de 2004, à Universidade de Kent em Canterbury-UK e à Universidade de Wales em Aberystwyth-UK, sob a supervisão do Dr. Jon Timmis e do Dr. Mark Neal.



Em seguida, soma-se a saída das duas redes resultando em valores que determinam a velocidade dos motores do robô. Os motores, por sua vez, governam as duas rodas do agente robótico.

Depois do treinamento das RNA, o robô foi introduzido em uma arena composta de paredes (obstáculos) e uma fonte de luz (fonte de energia) localizada no centro da arena. A cada movimento do robô é feita uma nova leitura dos seus sensores de luz e de distância e, conseqüentemente, novos comandos são passados para o robô pelas duas RNA.

Conforme mencionado anteriormente no início da Seção 6.4, a leitura dos sensores de luz simulam altos níveis de ruído (recorda-se que o valor 50 simboliza máxima luminosidade e 500 simboliza ausência de luz). Tal fato pode ser observado na ilustração do menor valor detectado na leitura dos oito sensores de luz a cada iteração, durante 50.000 iterações (Figura 6.15). Neste experimento e nos próximos, uma iteração corresponde a um movimento do robô na arena.



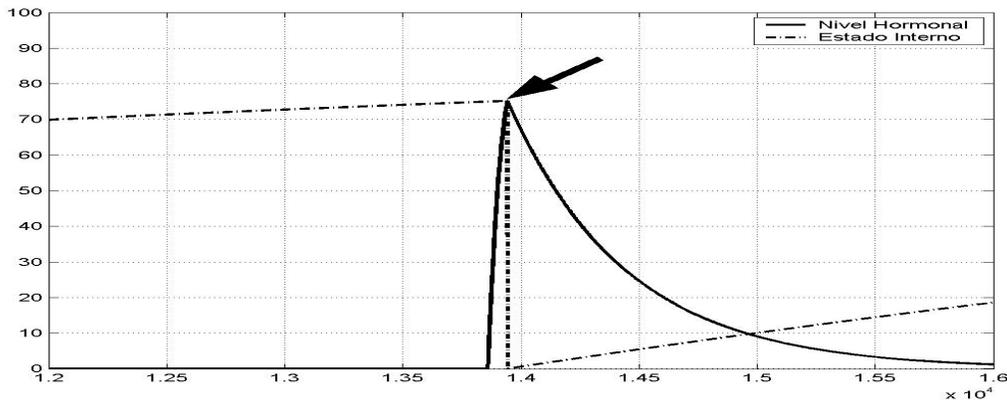
**Figura 6.15 - Experimento II: ilustração do valor do estímulo externo (fonte de luz) durante 50.000 iterações.**

Descreve-se a seguir, a variação dos valores do EI, do NH e do EE em torno da ocasião

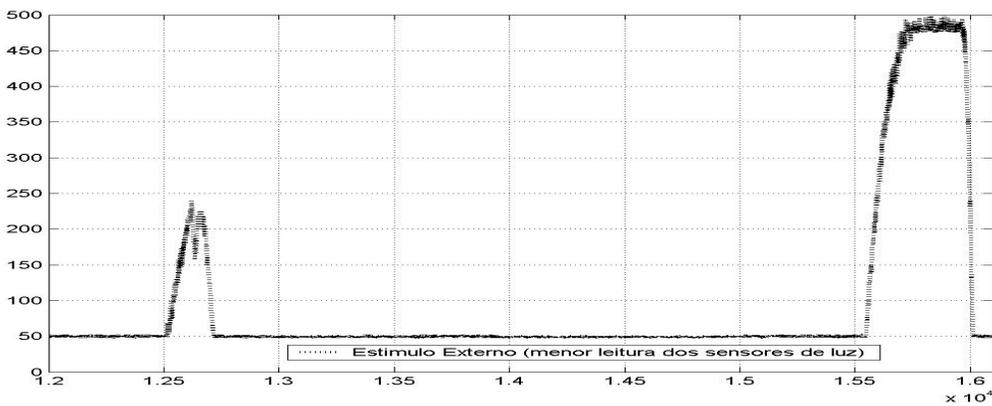
\*\*\* No caso da existência de mais de duas redes neurais poder-se-ia empregar uma combinação convexa.

na qual ocorre a primeira aproximação do robô ao alvo (fonte de luz) (instante assinalado na Figura 6.16 (a) por uma seta inclinada à direita). Lembra-se que o estado interno (EI) delineado refere-se à “necessidade” do robô de “recarregar” (necessidade de energia). Para tal, considere-se na Figura 6.16 (a) a variação do NH e do EI no intervalo entre a iteração 12.000 e a iteração 16.000, e na Figura 6.16 (b), a variação do EE neste mesmo intervalo.

Nota-se que, quando o EI atinge o valor igual a 75, o nível hormonal cresce chegando ao nível 75 rapidamente. Estes dois fatos, aliados à detecção de presença de luz representada na Figura 6.16 (b) pela leitura dos sensores próxima ao valor mínimo 50, determinam que o EI deve tornar-se nulo em torno da iteração 14.000, pois o robô já atingiu o seu alvo (fonte de luz) (instante assinalado por uma seta inclinada à direita na Figura 6.16 (a)).



(a)



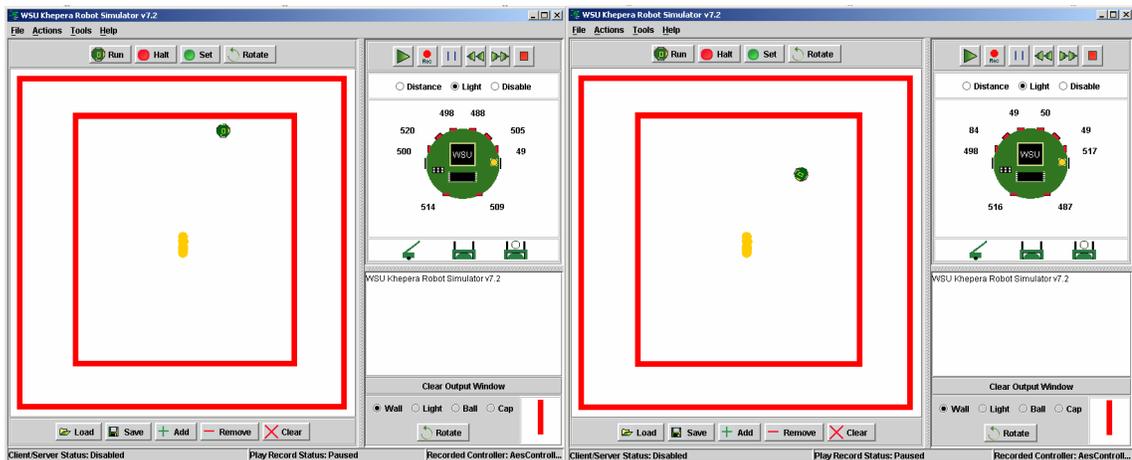
(b)

**Figura 6.16 – Experimento II: ilustração do valor das variáveis: nível hormonal NH, estado interno EI e estímulo externo EE durante a primeira aproximação do robô ao alvo ou fonte de “energia” (ponto de luz).**

As ilustrações da Figura 6.17 representam os passos do robô no simulador em torno da iteração 14.000 ilustrada na Figura 6.16 (a) e na Figura 6.16 (b). Como uma iteração corresponde a um movimento do robô na arena, cada movimento do robô representa a execução da ação ordenada pelas RNA, projetadas para comandar a velocidade das duas rodas do robô. Esta velocidade pode variar de  $-3$  a  $+3$  unidades.

Assim que o robô inicia a navegação, seu comportamento é governado somente pelo sistema endócrino artificial, através da ponderação das saídas das RNA a cada iteração. O sistema endócrino artificial controla as duas RNA pelo gerenciamento do estado interno do robô (necessidade de recarga) empregando todos os mecanismos endócrinos descritos na Seção 6.3.

Note na seqüência de imagens da Figura 6.17, da esquerda para a direita e de cima para baixo, que o robô alcança o alvo, satisfaz sua necessidade de recarregar e, em seguida, retorna ao comportamento de seguir paredes. Esta cessação na necessidade de recarregar ocorre em consequência do fato de que, quando o robô atinge o alvo (fonte de luz), o seu nível hormonal começa a *decrecer* até atingir um valor mínimo (zero neste caso), o que *inibe* a sua necessidade de recarregar. Esta inibição é representada pela volta do robô ao comportamento de seguir paredes.



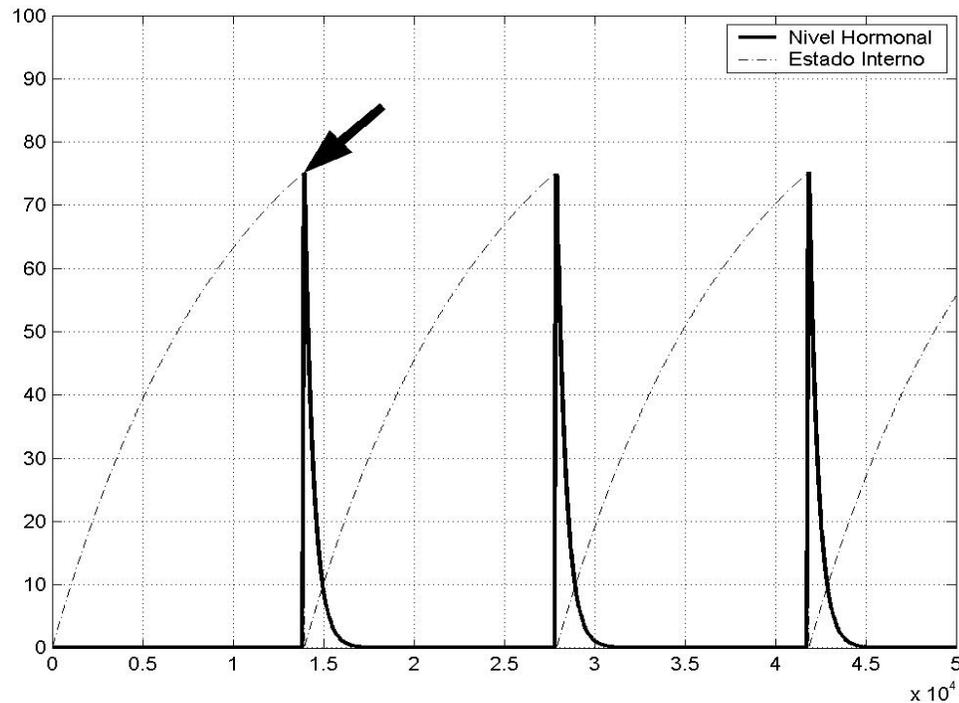
(a)



**Figura 6.17 – Experimento II: seqüência de passos do robô (a), (b) e (c) (da esquerda para a direita) juntamente com leitura dos sensores de luz. O robô se move do canto direito em direção à fonte de luz no centro da arena e depois de volta à parede. O ponto da parede (limite do ambiente de navegação) que é atingido pelo robô é arbitrário.**

Após esta demonstração, é adequado analisar todo o desempenho do sistema durante as 50.000 iterações de exposição ao EE ilustrado na Figura 6.15. A Figura 6.18 ilustra a variação do valor do nível hormonal e estado interno referentes ao estímulo externo ilustrado na Figura 6.15 durante as 50.000 iterações.

No instante  $t = 0$ , o estado interno (EI) é nulo e, portanto, a produção de hormônio não é estimulada. O estado interno depende do nível de estímulo externo (EE) e do nível hormonal (NH) presentes no agente artificial (Seção 6.3.3, Regra 6.1).



**Figura 6.18 – Experimento II: ilustração do valor das variáveis: nível hormonal NH e estado interno EI referentes ao estímulo externo EE ilustrado na Figura 6.15, durante 50.000 iterações.**

Para  $t > 0$ , o estado interno começa a crescer a uma taxa  $\beta = 0,0001$ , até que o mesmo atinge um nível no qual o NH começa a crescer rapidamente até atingir o valor limite igual a 75, indicando que há nível hormonal suficiente para estimular o comportamento de busca pela fonte de energia. Neste momento, em torno do instante  $t = 14.000$  iterações (instante assinalado por uma seta inclinada à direita na Figura 6.18), o valor do EI reduz-se a zero, indicando que, com a proximidade do robô ao alvo (fonte de luz), extingue-se a necessidade de “recarregar”.

Simultânea à queda do EI, a produção de hormônio também cessa, causando o início da queda do nível hormonal regido pela meia-vida do hormônio. Esta queda pronuncia-se até que o EI ultrapasse outra vez um limite predefinido, o que estimula novamente a produção de hormônio. O valor alto do nível hormonal associado à proximidade do alvo levou o robô a satisfazer sua necessidade de recarregar quatro vezes durante o experimento,  $t = \{14.000, 27.500, 42.000 \text{ e } 56.000\}$  iterações (veja a Figura 6.18). Este fato confirma a influência do nível hormonal sobre o comportamento do robô.

O comportamento *aparentemente* cíclico do robô justifica-se somente pela trajetória adotada pelo mesmo em torno da fonte de luz localizada no centro da arena. Caso outra trajetória tivesse sido adotada, poderia não ocorrer um comportamento cíclico.

### 6.4.3 Experimento III

O objetivo principal deste experimento é demonstrar que o agente robótico *simulado* possui capacidade de se adaptar a um ambiente dinâmico, apresentando o fenômeno biológico de comportamento cíclico sincronizado ao montante de recursos disponíveis através de um controle homeostático.

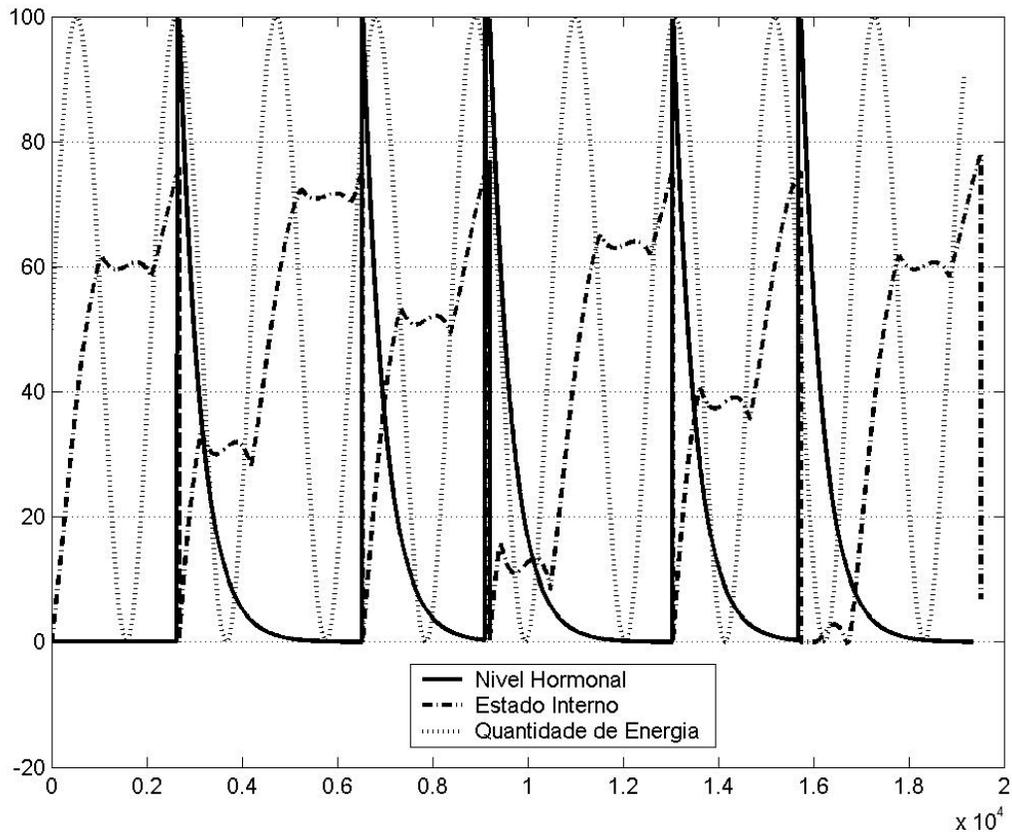
Aqui também se utilizou o simulador WSU Khepera Simulator (PERRETTA & GALLAGHER, 2003) explorando um cenário em que as ações do robô são influenciadas por dois estímulos externos: a distância até o alvo ou fonte de energia e a disponibilidade cíclica e variável de energia, representada pela variável QE (quantidade de energia).

Este experimento é dividido em duas simulações, A e B. Na simulação A, a QE é criada com base em uma curva senoidal suave e seu valor influencia o parâmetro  $\beta$  da equação presente na Regra 6.1, que regula o crescimento do estado interno (EI):

$$\begin{aligned} &\text{Se } \text{sen}(\theta) > 0,5 \\ &\text{então } \beta = \beta + \text{sen}(\theta), \\ &\text{senão } \beta = \beta - \text{sen}(\theta). \end{aligned} \qquad \text{Regra 6.3}$$

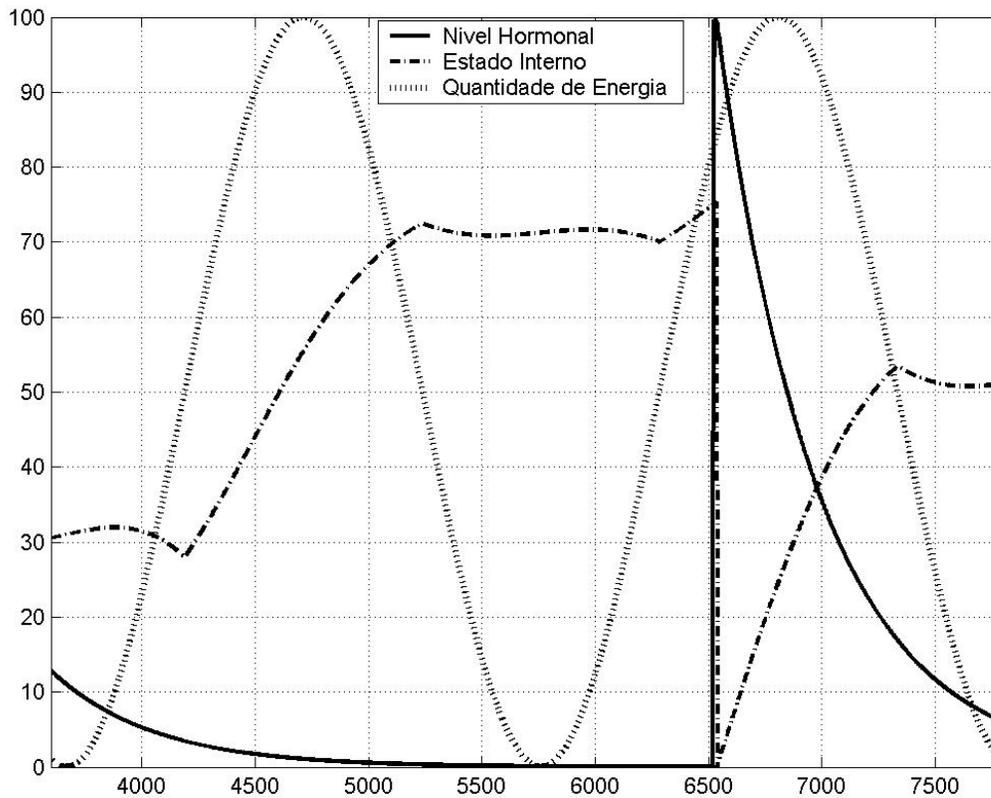
Na simulação B, a QE é criada com base em uma curva senoidal quantizada e seu valor também influencia o parâmetro  $\beta$  da Regra 6.1, que regula o crescimento do estado interno do robô (Regra 6.3). Esta simulação em particular é conduzida com o intuito de facilitar experimentos futuros com o robô Khepera II<sup>®</sup>. Por exemplo, a QE poderia ser implementada como níveis quantizados de frequência de uma luz piscante.

A variação do parâmetro  $\beta$  no tempo promove um comportamento auto-adaptativo para o robô, que apresenta uma tendência de “recarregar” somente quando o valor da QE é maior que 50 (em uma escala de 0 a 100) (Figura 6.19).



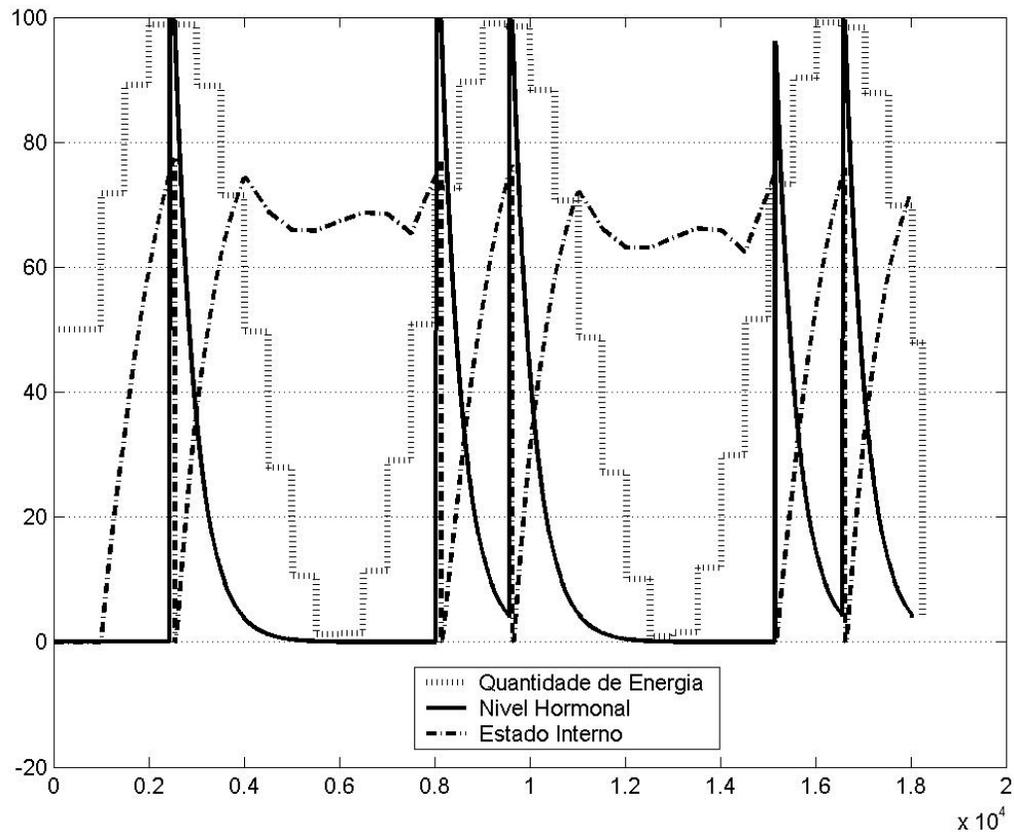
**Figura 6.19 - Experimento III-A: comportamento síncrono do robô para um estímulo senoidal suave representando a quantidade de energia disponível.**

A adaptabilidade do sistema, ressaltada na Figura 6.19, justifica-se pelo comportamento cíclico observado quando a necessidade do robô de recarregar entra em sincronismo com a disponibilidade alta de “energia” (valores em torno dos picos da senóide). Importante ressaltar que o que se busca não é uma sincronia perfeita, mas sim a emergência de um comportamento no robô de buscar a máxima disponibilidade de “energia”. Como a sincronia não é perfeita, esta recarga pode ocorrer um pouco antes ou um pouco depois do instante de máxima disponibilidade de energia (Figura 6.20). Pode-se observar que alguns instantes de máxima disponibilidade de energia podem também ser negligenciados, assim como outros podem estar associados a mais de uma recarga. Portanto, pode-se afirmar que o modelo proposto de sistema homeostático artificial fez com que o robô se adaptasse à dinâmica cíclica imposta pelo ambiente, sem nenhum modelo interno deste ambiente.



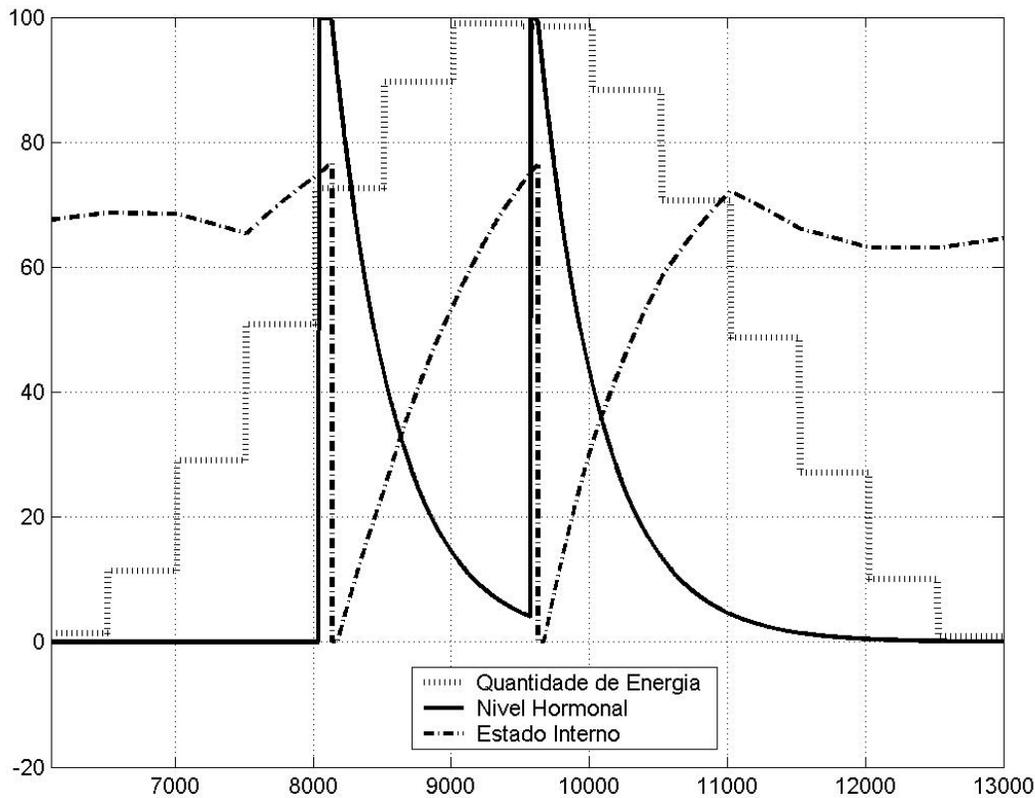
**Figura 6.20 - Experimento III-A: ilustra os valores variáveis de nível hormonal (NH), estado interno (EI) e quantidade de energia (QE) no intervalo em que o robô salta um pico de máxima disponibilidade de “energia” para “recarregar” em outro.**

Na simulação B, novamente observa-se uma tendência ao sincronismo em torno dos pontos de maior disponibilidade de “energia” (Figura 6.21).



**Figura 6.21 - Experimento III-B: comportamento síncrono para um estímulo senoidal em degrau.**

Em alguns casos, ocorrem duas aproximações em torno do mesmo pico (Figura 6.22). Isto se justifica, pois na primeira tentativa havia pouca quantidade de “energia”, o que fez com que o agente robótico volta-se ao comportamento de busca pela fonte logo em seguida, visto que o mesmo detectou um aumento quase que imediato na disponibilidade de energia.



**Figura 6.22 - Experimento III-B – ilustra o comportamento das variáveis nível hormonal (NH), estado interno (EI) e quantidade de energia (QE) durante duas aproximações em um mesmo intervalo de alta disponibilidade de energia.**

Essas duas últimas simulações A e B do **Experimento III** confirmam a habilidade do sistema em se adaptar a um ambiente dinâmico, apresentando um comportamento cíclico sincronizado com a disponibilidade de energia. Esta especialidade caracteriza a emergência do ciclo de controle biológico da homeostase, onde tanto processos internos como fatores externos podem regular e controlar o sistema.

#### 6.4.4 Experimento IV

Neste experimento, aplicam-se os conceitos de inteligência incorporada em um agente robótico *real*. A idéia central deste experimento preliminar é *transferir* para o robô real o mesmo sistema controlador desenvolvido no simulador para o **Experimento II** (Seção 6.4.2), permitindo-se apenas a sintonia fina dos valores detectados pelos sensores do robô *real*, que normalmente diferem um pouco do agente robótico *simulado*. A partir desta transferência, torna-se possível avaliar tanto as diferenças entre os dois ambientes, quanto o comportamento do robô frente a novos desafios.

Recorda-se que o sistema homeostático artificial proposto nesta tese é composto por duas redes neurais artificiais e um sistema endócrino artificial. Neste **Experimento IV**, assim como ocorreu nos **Experimentos II e III** (Seções 6.4.2 e 6.4.3), este sistema também será empregado para controlar a manifestação de comportamento em um agente robótico.

Com o objetivo de facilitar a transferência do sistema completo, do agente *simulado* para o robô *real*, decidiu-se por dividir o **Experimento IV** em três etapas. Na Etapa 1, observar-se o desempenho do robô quando controlado apenas pela primeira rede neural artificial, a qual foi treinada para seguir paredes e desviar de obstáculos. Na Etapa 2, analisa-se a performance do robô sob o controle isolado da segunda rede neural artificial, que foi treinada para seguir uma fonte de luz. Finalmente, na Etapa 3, emprega-se o sistema homeostático artificial completo, com o objetivo de controlar a manifestação de comportamento no robô.

Os ensaios foram realizados em uma arena de madeira branca, projetada e construída especificamente para realizar experimentos como o robô Khepera II dentro do LBiC<sup>†††</sup>. A arena tem o formato quadrado e possui 1,44 metros quadrados de área. A arena possui também acessórios que fazem o papel de delimitadores ou obstáculos, na forma de blocos retangulares de isopor branco em vários comprimentos, mas todos com 7 cm de altura e 7 cm de largura. Como poderá ser observado nos ensaios, estes blocos permitem que se criem vários cenários dentro da arena central.

---

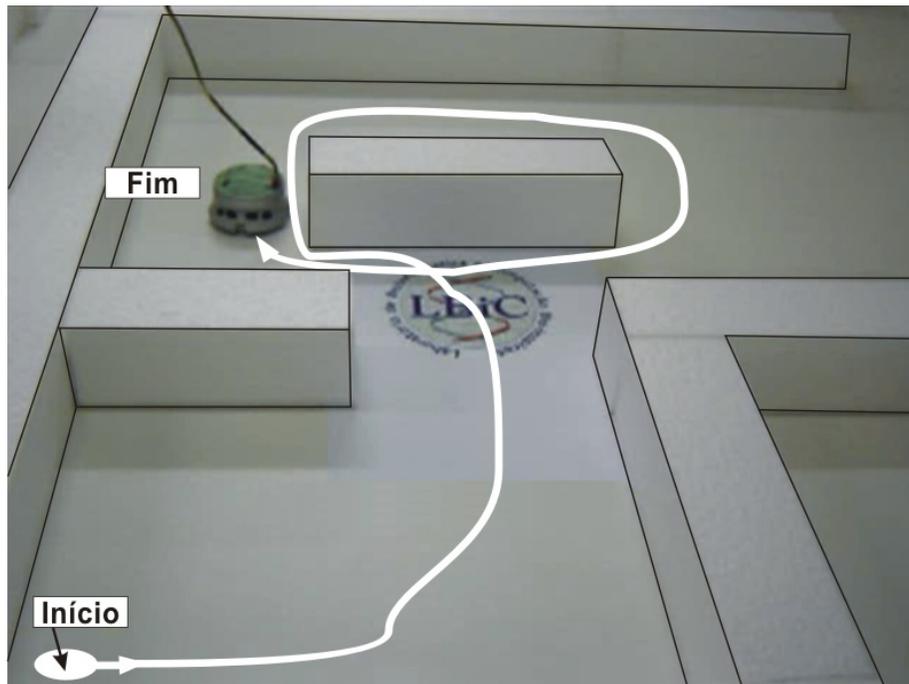
<sup>†††</sup> LBiC – Laboratório de Bioinformática e Computação Bio-Inspirada, DCA, FEEC, Unicamp (www.lbic.fee.unicamp.br).

As informações provenientes dos sensores são: a distância dos obstáculos, no caso da Etapa 1, grau de luminosidade, no caso da Etapa 2, e ambos, no caso da Etapa 3.

▪ **Etapa 1**

Nesta etapa, o robô é controlado somente pela primeira rede neural artificial (RNA1), treinada para seguir paredes e evitar colisões. Em um primeiro desafio, o robô é submetido a um ambiente quase fechado, com uma única saída, sendo que logo em frente a esta única saída encontra-se um obstáculo. Foi necessário um ajuste na leitura dos sensores de distância, multiplicando-se por 3 (três) os valores capturados, de modo que a leitura se assemelhasse à leitura obtida nas amostras utilizadas para treinar a rede neural artificial.

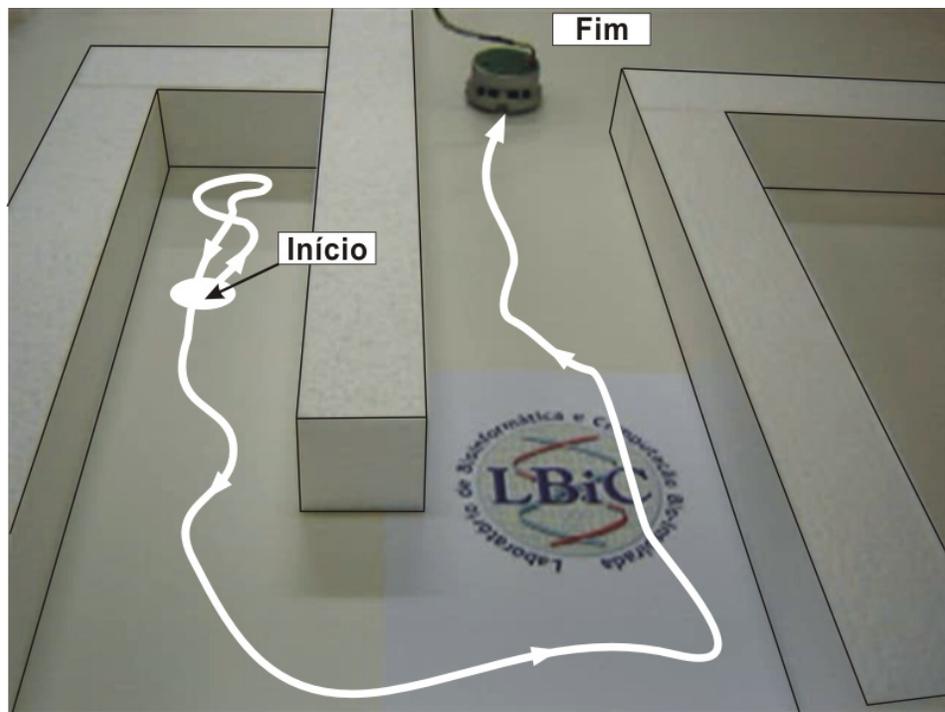
A Figura 6.23 ilustra o ambiente e toda a trajetória do robô para este primeiro desafio. Observa-se que, sem colisões, o robô consegue sair do ambiente quase fechado indo em direção ao obstáculo localizado logo em frente à única saída. Em seguida, o robô começa a andar em torno do obstáculo.



**Figura 6.23 – Experimento IV, Etapa 1, Desafio 1 – Sem colisões, o robô consegue sair do ambiente quase fechado indo em direção ao obstáculo localizado logo em frente à única saída. Em seguida, o robô começa a andar em torno do obstáculo.**

Em um segundo desafio, o robô, controlado pela mesma rede neural, é inserido em um beco estreito de frente para a parede que fica no final do beco. Este é um dos problemas mais desafiadores em navegação autônoma de robôs, pois o robô encontra-se cercado e todos os sensores frontais apresentam-se saturados, ou seja, captam obstáculos.

Veja na Figura 6.24 o ambiente e toda a trajetória do robô para este segundo desafio. Nota-se que, igualmente sem colisões, o robô segue primeiramente até o final do beco e gira sobre o próprio eixo em torno de 180 graus. Em seguida ele tangencia as paredes e segue em direção à saída.



**Figura 6.24- Experimento IV, Etapa 1, Desafio 2 – Sem colisões, o robô segue primeiramente até o final do beco e gira sobre o próprio eixo em torno de 180 graus. Em seguida ele tangencia as paredes e segue em direção à saída.**

- **Etapa 2**

Nesta etapa, o robô é controlado somente pela segunda rede neural (RNA2), treinada para seguir uma fonte de luz. O desafio é verificar o desempenho do robô na tarefa de seguir

uma fonte de luz que se move. Não foi necessário um ajuste na leitura dos sensores de luz, o que significa que a leitura se assemelha à leitura obtida nas amostras utilizadas para treinar a rede neural artificial.

A Figura 6.25 ilustra a seqüência de movimentos (da esquerda para a direita e de cima para baixo) do robô na tentativa bem sucedida de seguir uma fonte de luz que se move. Observou-se que existe um tempo mínimo de resposta necessário para que a rede neural artificial tome a decisão correta, controlando a movimentação do robô.



Figura 6.25 - Experimento IV, Etapa 2 – Seqüência de movimentos do robô seguindo uma fonte de luz que se move.

▪ **Etapa 3**

Nesta etapa, o robô é governado pelo sistema homeostático artificial (SHA), que irá controlar a manifestação de comportamento do robô. Recorda-se que o robô possui um estado interno que simula necessidade de recarga com base no nível de sua bateria interna. Apesar do robô Khepera II disponibilizar esta informação, foi adotado um nível de bateria hipotético e não o nível de bateria do próprio robô. A justificativa para esta decisão está no fato dos experimentos serem realizados com o robô sendo alimentado por uma fonte de energia, permitindo assim que o tempo de duração dos experimentos fosse irrestrito. O cenário é cercado por paredes e com uma fonte de luz no centro. Todos os parâmetros adotados são os mesmos do **Experimento II** (Seção 6.4.2).

Como no início da navegação o estado interno do robô é nulo, ou seja, sua necessidade de recarga é nula, o SHA define que o robô deve ser controlado pela RNA1 (seguir paredes sem colisão). À medida que seu estado interno vai aumentando, sua necessidade de recarga também cresce e, a partir de um determinado valor, o SHA define que o robô deve ser controlado pela RNA2 (seguir em direção à luz).

Ilustra-se, a seguir, o desempenho do robô em um mesmo ambiente, em dois ensaios, usando o mesmo controlador. Em cada um, o robô parte de uma posição inicial distinta (Figura 6.26 e Figura 6.27).

A Figura 6.26 esboça a trajetória completa do robô Khepera em um ambiente cercado por paredes e com uma fonte de luz no centro. O robô inicia a navegação buscando a parede mais próxima e segue tangenciando-a. Assim que o nível de seu estado interno ultrapassa um limite predeterminado, o SHA define, através do aumento do nível hormonal que age sobre as saídas das RNA, que o robô deve seguir em direção à luz (para recarregar sua bateria). Assim que o robô chega bem próximo à luz, seu nível hormonal começa a decrescer e o robô volta para o comportamento de seguir paredes.

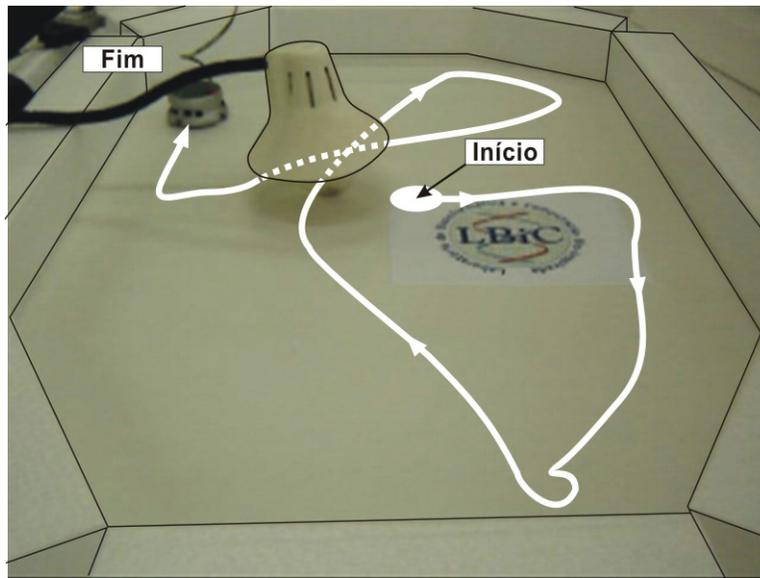


Figura 6.26- Experimento IV, Etapa 3, Ensaio 1 – Trajetória completa do robô Khepera em um ambiente cercado por paredes e com uma fonte de luz no centro. O robô inicia a navegação buscando a parede mais próxima e segue tangenciando-a. Depois, segue em direção à luz. Na sequência, volta a procurar a parede mais próxima. Em seguida, a luz novamente e depois a parede.

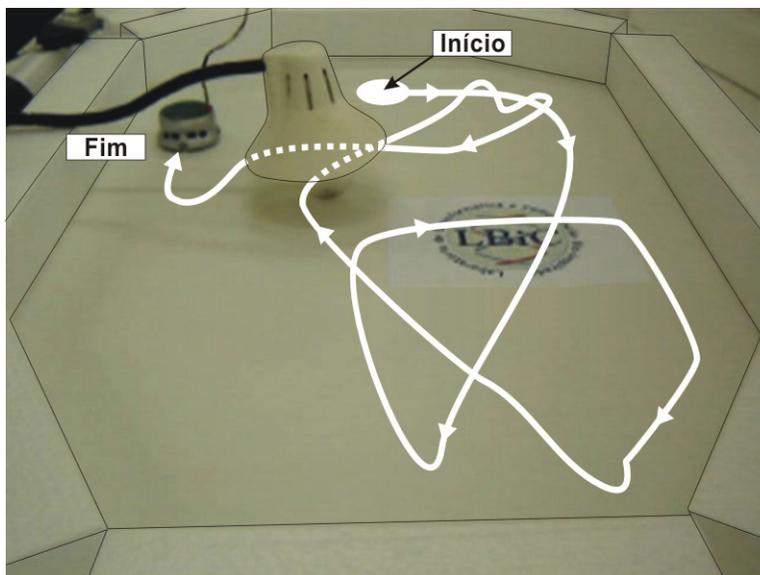


Figura 6.27 - Experimento IV, Etapa 3, Ensaio 2 – Trajetória completa do robô Khepera no mesmo ambiente da Figura 6.26. O robô inicia a navegação ao lado de uma parede e segue tangenciando-a, depois segue em direção à luz. Depois, volta a procurar a parede mais próxima. Em seguida, a luz novamente e, depois, a parede novamente e assim por diante.

Observa-se que o mesmo ocorre no Ensaio 2. A Figura 6.27 ilustra a trajetória completa do robô Khepera no mesmo ambiente da Figura 6.26. O robô começa a navegação ao lado de uma parede e segue tangenciando-a. Depois, segue em direção à outra parede na parte de baixo da arena e, em seguida, caminha em direção à luz. Depois, volta a procurar a parede mais próxima. Em seguida, a luz novamente e, depois, a parede novamente e assim por diante.

Nos dois ensaios, o robô seguiu sem colisões e reagiu prontamente à mudança do nível hormonal imposta pelo SHA em resposta ao seu estado interno. Com base neste experimento, pôde-se verificar que o desempenho do robô atesta a eficiência da nova proposta, ainda que para um problema específico de controle autônomo de robôs.

#### **6.4.5 Análise dos Experimentos e Resultados**

Buscou-se durante os experimentos explorar todas as faces da proposta inicial de um sistema homeostático artificial. Em resumo, esta exploração contemplou ajuste de parâmetros, preparação e adequação de conjunto de dados amostrais e verificação de desempenho do sistema como um todo, tanto em ambientes simulados e como em ambientes reais (VARGAS *et al.*, 2005).

A seqüência de experimentos adotada se mostrou adequada, em virtude da possibilidade de transposição de parâmetros e estratégias entre experimentos simulados e também entre experimentos simulados e experimentos reais. Através do Experimento I, foi possível uma primeira análise do comportamento das variáveis do sistema frente a um estímulo fictício. Com esta simulação, foi possível um primeiro cálculo e teste de valores adequados aos parâmetros do sistema, o que facilitou a adaptação dos mesmos aos experimentos subseqüentes. Os resultados obtidos com os Experimentos II e III serviram ao propósito de facilitar a transição do sistema para o agente robótico real no Experimento IV. Com base nesta experiência, pode-se confirmar o papel da simulação como um fator crítico e extremamente importante durante o desenvolvimento de controladores robóticos. Fatores como tempo despendido nos testes de controladores e ajuste de sensores nos robôs reais podem se tornar dramáticos caso se decida pela não utilização do ambiente simulado em uma primeira instância.

Por se tratar de um simulador de código aberto, o WSU Khepera Simulator apresenta alguns problemas de implementação, os quais tiveram que ser contornados durante os experimentos de forma a não afetar a análise do desempenho do sistema no ambiente simulado. Quanto aos experimentos com o robô real, um fator crítico, já mencionado anteriormente, refere-se à utilização dos mesmos sensores para detecção de obstáculos e de fontes de luz. Este problema foi amenizado pelo controle de exposição da luz durante os experimentos.

É importante ressaltar que a tentativa de controle da luminosidade do ambiente durante os experimentos mostrou-se em alguns momentos ineficaz, de forma que o comportamento do robô não condizia com o esperado. Apesar desses problemas técnicos, todos os resultados obtidos confirmaram a eficiência da nova proposta e podem ser considerados como um estímulo à extensão de pesquisas futuras na área de sistemas homeostáticos artificiais.

Acredita-se que cada experimento desempenhou uma função primordial e distinta como um primeiro passo na busca de um sistema biologicamente inspirado capaz de realizar um controle homeostático de um organismo artificial. Após essa primeira etapa crucial, vislumbram-se inúmeras possibilidades de extensão da proposta, a serem apresentadas no Capítulo 7.

Outros pontos passíveis de investigação englobam a forma de atuação do sistema endócrino artificial sobre as redes neurais artificiais e a modelagem do módulo CPH (controlador de produção de hormônios). Recordar-se que, nessa proposta inicial, o controle das redes ocorre pela multiplicação direta do nível hormonal pelas saídas das redes. Conjetura-se que formas alternativas podem e devem ser exploradas, sobretudo aquelas que buscam inspiração nos processos biológicos da natureza. Sugestões adicionais serão discutidas no Capítulo 7.

## 7. CONCLUSÃO

7. CONCLUSÃO.....	157
7.1. Análise das Principais Contribuições da Tese .....	157
7.2. Perspectivas Futuras .....	158
7.2.1 CLARINet.....	159
7.2.2 Sistema Homeostático Artificial.....	160
7.2.3 Sistemas Computacionais Bio-Inspirados.....	161

Este capítulo aborda inicialmente uma análise das principais contribuições desta tese. Em seguida, articulam-se propostas de perspectivas futuras tanto para a área de sistemas computacionais bio-inspirados quanto para as ferramentas propostas.

### 7.1. Análise das Principais Contribuições da Tese

Os sistemas biológicos *crecem* e se *adaptam*, enquanto que, até recentemente, a maioria dos sistemas computacionais eram apenas *projetados* e *construídos* para solucionar problemas específicos. Hoje, a *computação bio-inspirada* é uma realidade e caracteriza-se pela progressiva busca por inspiração na biologia como metáfora para criação de algoritmos computacionais para solução de problemas.

Em linhas gerais, pode-se descrever a computação bio-inspirada como o uso de computadores para modelar processos da natureza visando o atendimento de algum objetivo específico. Esta tese investigou sistemas computacionais bio-inspirados aplicados à síntese de controle autônomo, procurando sempre que possível criar modelos *plausíveis* biologicamente.

Através de milhões de anos de evolução, organismos biológicos desenvolveram e ainda desenvolvem soluções eficazes para problemas complexos que encontram similares e equivalentes na engenharia. Deste modo, é razoável afirmar que modelos computacionais bio-inspirados devem continuamente buscar um elevado nível de *fidelidade* à fonte de inspiração biológica. O resultado desta busca será retratado nos sistemas computacionais pela incorporação

de características intrínsecas aos sistemas biológicos presentes na natureza. Como por exemplo: descentralização, adaptação, escalabilidade, auto-organização e robustez.

Com foco neste objetivo fundamental, as principais contribuições desta tese podem ser assim enumeradas:

- 1) uma classificação circunstancial dos sistemas complexos;
- 2) definição de uma estrutura unificada de descrição para sistemas complexos;
- 3) utilização da estrutura unificada de descrição para apresentar três sistemas: as redes neurais artificiais, os sistemas imunológicos artificiais e os sistemas endócrinos artificiais;
- 4) uma abordagem unificada com base nos conceitos de sistemas híbridos incorporados, com ênfase na modelagem de sistemas computacionais bio-inspirados, envolvendo sistemas classificadores com aprendizado e sistemas imunológicos artificiais;
- 5) uma abordagem integrada de um sistema homeostático artificial envolvendo redes neurais artificiais e um novo modelo de sistema endócrino artificial;
- 6) aplicação dos sistemas propostos em navegação autônoma de robôs, incluindo simulações computacionais e experimentos com robôs reais do tipo Khepera II<sup>®</sup>.

Para os experimentos com robôs reais, foi desenvolvida uma interface gráfica (GUI – “*Graphical User Interface*”, na literatura em inglês) voltada para o gerenciamento da comunicação serial entre o controlador e o robô real Khepera II<sup>®</sup>.

As duas propostas de modelos computacionais bio-inspirados, correspondentes aos itens 4 e 5 das contribuições, serão melhor detalhadas na próxima seção.

## 7.2. Perspectivas Futuras

Observa-se atualmente uma tendência à multidisciplinariedade das linhas de pesquisa científica. Este fato reforça a opinião de que o futuro da computação e o futuro da biologia estão intimamente ligados. Vislumbra-se que, com esta ligação, ocorrerá um aumento na relação de troca, onde as duas ciências serão as principais beneficiadas. Espera-se que os comportamentos e

características intrínsecos aos sistemas biológicos presentes na natureza sejam um convite à conquista e estabelecimento definitivo de uma sinergia entre a biologia e a computação em um futuro próximo.

### 7.2.1 CLARINet

As perspectivas futuras para a CLARINet são inúmeras. É oportuno ressaltar que, ao se sugerir qualquer alteração no modelo original da CLARINet, deve-se atentar para o fato de que está se lidando com um sistema híbrido do tipo incorporado. Embora seja perceptível a distinção entre os subsistemas, eles são hibridizados de forma a compor um sistema maior e mais sofisticado que requer a atuação conjunta dos subsistemas para promover ações mais eficientes. Desse modo, todas as decisões devem ser tomadas sempre considerando as peculiaridades dos dois sistemas: o sistema classificador com aprendizado e a rede imunológica artificial.

Caso se decida dar continuidade à aplicação da CLARINet a problemas de navegação autônoma de robôs, basicamente dois pontos são decisivos nas próximas investigações: o projeto e aplicação do algoritmo genético do sistema classificador e o procedimento de recompensa e punição.

Com relação ao algoritmo genético, verificou-se que um desempenho satisfatório da CLARINet está vinculado à utilização com êxito desta ferramenta evolutiva. Sendo assim, seguem-se algumas sugestões para as próximas investigações:

- 1) a aplicação do algoritmo genético pode ser vinculado ao desempenho do sistema, como sugerido por DORIGO & COLOMBETTI (1997), ou então pode seguir a linha de raciocínio adotada por RICHARDS (1995), na qual ele divide a evolução de um sistema classificador em duas fases, uma de aprendizado e outra de aplicação.
- 2) aspectos de manutenção de diversidade do algoritmo genético devem ser tratados no sentido de evitar a convergência prematura.
- 3) pode-se incluir um tipo de filtro antes da inclusão na rede dos filhos gerados pelo algoritmo genético. Por exemplo, poder-se-ia adotar parte de um dos processos que

Watanabe e colaboradores (WATANABE *et al.*, 1998; WATANABE *et al.*, 1999) sugerem em seus trabalhos, nos quais se inclui somente um filho de cada vez e com base em uma medida empregada com sucesso conforme relatos apresentados em sua proposta de rede imunológica para navegação autônoma de robôs.

Tanto DORIGO & COLOMBETTI (1997) quanto NOLFI & FLOREANO (2000) ressaltam que os agentes robóticos simulados e reais possuem uma sensibilidade aguçada em relação a procedimentos de recompensa e punição. Este fato, aliado à composição híbrida da CLARINet, sugere a adoção de critérios mais específicos que contribuam para a evolução do sistema como um todo.

Outras sugestões incluem adotar uma porcentagem alta de “*don't care*” na população inicial (acima de 50%). A porcentagem de “*don't care*” deve ser alta, pois já foi comprovado que o modelo original de HOLLAND (1992) incorporado na CLARINet precisa gerar blocos construtivos ou hierarquia de regras semelhantes com especificidades diferentes (VARGAS, 2000; VARGAS *et al.*, 2004).

A diminuição na quantidade de conexões da rede na população inicial, visando simplificar o processo, também faz parte do elenco de sugestões para propostas futuras. Em linhas gerais, os efeitos da adoção de critérios de parcimônia no modelo computacional resultante devem ser melhor investigados.

De modo geral, os próximos passos nesta linha de pesquisa envolvem a continuidade do emprego da CLARINet junto a agentes robóticos explorando problemas que não necessariamente requeiram soluções com trajetórias repetitivas e uma investigação de mecanismos sistemáticos de interpretação da rede de classificadores resultante do processo evolutivo.

## 7.2.2 Sistema Homeostático Artificial

Recorda-se que a proposta inicial de sistema homeostático artificial desta tese contempla a coordenação de duas redes neurais artificiais (RNAs) por um sistema endócrino artificial

(SEA). No entanto, poder-se-ia investigar a especificação da proposta de inclusão de um terceiro sistema, o sistema imunológico artificial (SIA). Para este fim, é imprescindível a definição clara do papel deste novo componente junto aos demais módulos do sistema.

Entre alternativas, especula-se que um ponto a ser explorado, quando da união com os dois outros sistemas, seria a capacidade singular do SIA em reconhecimento de padrões, manutenção de diversidade e estabelecimento de mecanismos de adaptação e auto-organização funcional e estrutural. Dessa maneira, pode-se cogitar a utilização do SIA para controlar o número e tipo de neurônios e de redes neurais artificiais e também o número e tipo de hormônios ou glândulas artificiais no SEA. Este processo poderia ocorrer através de mecanismos de maturação de afinidade ditados pelo desempenho do sistema homeostático. Uma outra opção para inclusão do SIA poderia ser por meio da divisão do controle das ações da RNA junto ao SEA, amenizando ou estimulando a produção de hormônios e recebendo também estímulos externos do ambiente.

De modo equivalente, observa-se que os hormônios produzidos pelo SEA poderiam atuar em outras frentes. Por exemplo, os hormônios poderiam atuar em um SIA moderando a reação a agentes invasores (antígenos).

### **7.2.3 Sistemas Computacionais Bio-Inspirados**

De partida, vislumbra-se como perspectiva futura o emprego da EUD a todos os sistemas computacionais bio-inspirados tratados nesta tese. Acredita-se que este estudo pode auxiliar na implementação das sugestões assinaladas ao longo da tese e na descoberta de novas abordagens.

Com base nos resultados experimentais, tanto simulados quanto reais, apresentados nos capítulos 5 e 6, e até mesmo com base na suposta implementação e validação de todas as perspectivas futuras enunciadas acima, não é possível responder afirmativamente e incondicionalmente a perguntas do tipo:

- os sistemas computacionais bio-inspirados oferecem alguma propriedade diferencial que esteja definitivamente ausente em sistemas computacionais não-bio-inspirados?
- supondo a existência de tais propriedades diferenciais, seriam os sistemas computacionais bio-inspirados capazes de proporcionar ganhos de desempenho significativo frente a outras propostas de concepção de sistemas complexos adaptativos?

Uma das razões para não se ter resposta afirmativa para tais questões, mesmo após a conclusão do projeto de pesquisa desta tese, é a dificuldade de caracterizar o universo dos sistemas computacionais não-bio-inspirados. Por não serem bio-inspirados, estes sistemas computacionais podem ser inspirados em algum outro paradigma ou não ser inspirados em nada específico. Neste último caso, a sua concepção não necessita estar fundamentada, de modo que nada impediria, em teoria, a concepção de um sistema computacional não-bio-inspirado idêntico em estrutura e funcionalidade a um sistema computacional bio-inspirado. Logo, as duas perguntas acima perderiam o sentido.

Mas o sentido das duas perguntas acima se mantém quando se pensa em fontes de inspiração alternativas. Neste caso, poder-se-ia questionar a ausência de resultados, nesta tese, referentes à comparação de desempenho da abordagem proposta com alguma alternativa existente na literatura, assim como a comparação de desempenho entre as próprias propostas dos capítulos 5 e 6. Até mesmo propostas originadas dentro do grupo de pesquisa poderiam ser consideradas para comparação, como aquelas apresentadas por MICHELAN (2003) e CAZANGI (2004). No entanto, existem dois argumentos para justificar a ausência de tais comparações:

- embora as propostas candidatas à comparação também fossem concebidas para síntese de controle autônomo, os objetivos e o enfoque metodológico que sustentam cada proposta não são os mesmos, dificultando o estabelecimento de critérios de comparação imparciais;
- SIPPER (2002), um dos mais proeminentes pesquisadores na linha de computação bio-inspirada, manifesta uma forte convicção de que as pesquisas em sistemas computacionais bio-inspirados não devem ainda ser julgadas pela possibilidade de obtenção de resultados

imediatos e ganhos comparativos, embora devam estar ocupadas em atender aspectos de viabilidade prática em um futuro próximo.

Por mais desconfortável que esta posição possa se apresentar sob uma perspectiva de praticidade dos resultados obtidos, ela cria condições para que pesquisadores que buscam conceber sistemas computacionais bio-inspirados com vários graus de complexidade e fidelidade à fonte inspiradora não sofram pressões indevidas no sentido de transformar, a todo momento, um potencial de aplicação em desempenho efetivo.

É fato que os sistemas biológicos existentes (no contexto deste trabalho, são representados pelo sistema nervoso, pelo sistema endócrino e pelo sistema imunológico) são bem-sucedidos e cada qual se destaca na execução de tarefas variadas e de grande complexidade. Logo, embora seja possível discutir os meios empregados para se atingir um sistema computacional bio-inspirado que permita uma resposta afirmativa às duas questões acima, pode-se considerar os sistemas biológicos que os inspiram como representantes genuínos do seu potencial. Dessa forma, um sistema computacional bio-inspirado está em condições teóricas de conduzir a uma resposta afirmativa às duas perguntas acima.

Conclui-se então que, se os projetistas de sistemas computacionais bio-inspirados forem capazes de explorar mais e mais o potencial de suas concepções bio-inspiradas, mais se caminhará no sentido de produzir uma resposta afirmativa às duas questões acima, agora na prática. Espera-se que esta tese tenha contribuído no sentido de propor etapas inéditas nessa exploração e coloca-se como perspectiva futura o prosseguimento dessa busca.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ADLEMAN, L.M. (1994). “Molecular Computation of Solutions to Combinatorial Problems”, *Science*, 226, November, pp. 1021–1024.
- ANDERSSON, N., BROBERG, A., BRÄNBERG, A., JANLERT, L., JONSSON, E., HOLMLUND, K. & PETTERSSON, J. (2002). Emergent Interaction - a Pre-Study, Department of Computing Science, Umeå University, Sweden.
- ATMAR W. (1994). “Notes on Simulation of Evolution”, *IEEE Transactions on Neural Networks*, vol. 5, no. 1, pp. 130-147.
- AXELROD, R. (1984). *The Evolution of Co-operation*, Penguin Books, England.
- BÄCK, T., FOGEL, D. B. & MICHALEWICZ, Z. (EDS.) (2000a). *Evolutionary Computation 1: Basic Algorithms and Operators*, Institute of Physics Publishing.
- BÄCK, T., FOGEL, D. B. & MICHALEWICZ, Z. (EDS.) (2000b). *Evolutionary Computation 2: Advanced Algorithms and Operators*, Institute of Physics Publishing.
- BAK, P. (1996). *How Nature Works: The Science of Self-Organized Criticality*, Copernicus Books.
- BARTON, S. (1994). “Chaos, Self-Organization, and Psychology”, *American Psychologist*, vol. 49, pp. 5-14, 1994.
- BERDICHEVSKY, V. L. (1997). “Thermodynamics of Chaos and Order”, Longman.
- BESENDOVSKY, H. O. & DEL REY, A. (1996). “Immune-Neuro-Endocrine Interactions: Facts and Hypotheses”. *Endocrine Reviews*, 17(1), pp. 64-102.
- BEZDEK, J. C. (1992). “On the Relationship Between Neural Networks, Pattern Recognition and Intelligence”, *The International Journal of Approximate Reasoning*, vol. 6, pp. 85-107.

- BEZDEK, J. C. (1994). "What is Computational Intelligence?" em Zurada et al. Editores, Computational Intelligence : Imitating Life, IEEE Press, pp. 1-12.
- BLICKLE, T. (2000). "Tournament selection". Em Bäck, T., Fogel, D. B. e Michalewicz, T. (Eds). Evolutionary Computation 1, Institute of Physics Publishing, pp. 172-180.
- BOOKER, L. B., GOLDBERG, D. E. & HOLLAND, J. H. (1989). "Classifier Systems and Genetic Algorithms", Artificial Intelligence, vol. 40, pp. 235-282.
- BROOKS, R. (1991a). "Intelligence without representation". Artificial Intelligence, 47, pp. 139-160.
- BROOKS, R. (1991b). "Intelligence without reason", in J. Mylopoulos and R. Reiter (Eds.) Proceedings of the 12th International Joint Conference on Artificial Intelligence, Morgan Kaufmann.
- BURNET, F. M. (1959). The Clonal Selection Theory of Acquired Immunity, Cambridge University Press.
- BUSEMEYER, J.R. & TOWNSEND, J.T. (1993). "Decision Field Theory: A Dynamic-Cognitive Approach to Decision Making in an Uncertain Environment", Psychological Review, vol. 100, pp. 432-459.
- BUSHEV, M. (1994). Synergetics: Chaos, Order, Self-Organization, World Scientific Publishing Co. Pte. Ltd., London, UK.
- CAETANO, F. H., JAFFÉ, K. & ZARA, F. H. (2002). Formigas:Biologia e Anatomia, Editora Topázio.
- CAMAZINE, S., DENEUBOURG, J.-L., FRANKS, N.R., SNEYD, J., THERAULAZ, G. & BONABEAU, E. (2001). Self-Organization in Biological Systems, Princeton University Press.
- CANNON, W. B. (1929). "Organization for Physiological Homeostasis". Physiological Review, 9, 399-431.
- CAZANGI, R. R. (2004). Uma Proposta Evolutiva para Controle Inteligente em Navegação

- Autônoma de Robôs, Dissertação de Mestrado, DCA/FEEC/Unicamp e DIN/UEM-PR, Campinas/SP, Brasil, 135 páginas, Maio, 2004.
- CHAITIN, G. (1990). *Information, Randomness and Incompleteness*, 2nd ed., World Scientific, Singapore.
- CHURCHLAND, P. & SEJNOWSKI, T.J. (1994). *The Computational Brain*, MIT Press.
- COHEN, J. & STEWART, I. (1994). *The Collapse of Chaos – Discovering Simplicity in a Complex World*, Penguin Books.
- COPELAND, J. & PROUDFOOT, D. (2004). “AlanTuring.net: The Turing Archive for the History of Computing”, [http://www.cs.usfca.edu/www.AlanTuring.net/turing\\_archive/index.html](http://www.cs.usfca.edu/www.AlanTuring.net/turing_archive/index.html)
- COVENEY, P. & HIGHFIELD, R. (1995). *Frontiers of Complexity – The Search for Order in a Chaotic World*, Fawcett Columbine.
- COWAN, G., PINES, D & MELTZER, D. (EDS.) (1994). *Complexity: Metaphors, Models, and Reality. Proceedings Volume XIX*, Santa Fe Institute, *Studies in the Sciences of Complexity*, Addison-Wesley Pub. Company.
- DARWIN, C. (1859; 1993). *The Origin of Species by Means of Natural Selection or The Preservation of Favored Races in The Struggle for Life*. The Modern Library, New York.
- DASGUPTA, D. (ED.) (1999). *Artificial Immune Systems and their Applications*, Springer-Verlag.
- DAYAN, P. & ABBOT, L. F. (2001). *Theoretical Neuroscience: Computational and Mathematical Modelling of Neural Systems*, The MIT Press.
- DE CASTRO, L. N. & TIMMIS, J. (2002). *Artificial Immune Systems: A New Computational Intelligence Approach*, Springer-Verlag: London.
- DE CASTRO, L. N. (2003). “Immune Cognition, Micro-evolution, and a Personal Account on Immune Engineering”, *S.E.E.D. Journal (Semiotics, Evolution, Energy, and Development)*, Universidade de Toronto, v. 3, n. 3, p. 134-155.

- DE CASTRO, L. N. (2005). Natural Computing, In M. Khosrow-Pour (Ed.) *Encyclopedia of Information Science and Technology*, Idea Group Publishing.
- DE CASTRO, L.N. & VON ZUBEN, F. J. (EDS.) (2004). *Recent Developments in Biologically Inspired Computing*, Idea Group Publishing.
- DE ROSNAY, J. (1979). *The Macroscopic: a New World Scientific System*. English translation, by Harper & Row, Publishers, Inc.
- DE ROSNAY, J. (1998). " Entropy and the Laws of Thermodynamics", em F. Heylighen, C. Joslyn and V. Turchin (editores): *Principia Cybernetica Web* (Principia Cybernetica, Brussels), URL: <http://pespmc1.vub.ac.be/ENTRATHER.html>
- DEJONG, K. (1975). *The Analysis and Behaviour of a Class of Genetic Adaptive Systems*, Tese de Doutorado, University of Michigan.
- DENBIGH, K. G. (2004). "Note on Entropy, Disorder and Disorganization", electronic report.
- DORIGO, M. & COLOMBETTI, M. (1997). *Robot Shaping: An Experiment in Behaviour Engineering (Intelligent Robotics and Autonomous Agents)*, MIT Press.
- ELOWITZ, M. B. & LEIBLER, S. M. (2000). "A Synthetic Oscillatory Network of Transcriptional Regulators," *Nature*, Vol. 403, No. 6,767, 2000, pp. 335–338.
- FARMER, J. D. (1990). "A Rosetta Stone for Connectionism", *Physica D*, vol. 42, pp. 153-187.
- FARMER, J. D., PACKARD, N. H. & PERELSON, A. S. (1986). "The Immune System, Adaptation and Machine Learning", *Physica 22D*, pp. 187-204.
- FAUSETT, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice Hall.
- FERREIRA, A. B. H. (1999). *Novo Dicionário Aurélio - Século XXI*. Editora Nova Fronteira.
- FOGEL, D. B. (1995). *Evolutionary Computation: Toward a New Philosophy of Machine Intelligence*. IEEE Press.

- FORBES, N. (2004). *Imitation of Life: How Biology is Inspiring Computing*, MIT Press.
- FORREST, S. (1990). “Emergent Computation: Self-organizing, Collective, and Cooperative Phenomena in Natural and Artificial Computing Networks”, *Physica D*, Vol. 42, pp. 1-11.
- FURUHASHI, T., NAKAOKA, K. & UCHIKAWA, Y. (1994). "A Study on Fuzzy Classifier System for Finding Control Knowledge of Multi-Input Systems", *Genetic Algorithms And Soft Computing*, pp. 489-502.
- GALLAGHER, R. & APPENZELLER, T. (1999). “Beyond Reductionism”, *Science*, 284 (5411).
- GALLY, J. A., MONTAGUE, P. R., REEKE, G. N. JR & EDELMAN, G. M. (1990), “The NO hypothesis: possible effects of a short lived, rapidly diffusible signal in the development and function of the nervous system”, *Proceedings of the National Academy of Science USA*, 87, 3547-3551.
- GARDNER, H. (1993). *Frames of Mind*, 10th Edition, Basic Books, NY.
- GARDNER, T.S. (2000). “Construction of a Genetic Toggle Switch in *Escherichia Coli*,” *Nature*, Vol. 403, No. 6,767, pp. 339–342.
- GASPAR, A. & HIRSBRUNNER, B. (2002). “From Optimization to Learning in Changing Environments: The Pittsburgh Immune Classifier System”, *Proc. of the First International Conference on Artificial Immune Systems (ICARIS-2002)*, University of Kent at Canterbury, UK, September 9th-11th , pp. 190-199.
- GOLDBERG, D. E. (1983). *Computer-Aided GAs Pipeline Operation using Genetic Algorithms and Rule Learning*, Tese de Doutorado, University of Michigan, Ann Arbor, MI.
- GOLDBERG, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, Inc.
- GOLDENFELD, N. & KADANOFF, L. P. (1999). “Simple Lessons from Complexity”, *Science*, 284 (5411), pp. 87-89.
- GOODWIN, B. (1994). *How the Leopard Changed Its Spots*, Weidenfeld & Nicolson, London.

- GRASSÉ, P. P. (1959). “La Reconstruction du Nid et Les Coordinations Interindividuelles Chez *Bellicositermes Natalensis* et *Cubitermes* sp. La Théorie de la Stigmergie: Essai d’interprétation du Comportement des Termites Constructeurs”, *Insect. Soc.*, 6, pp. 41-80.
- GREEN, D. G. (1994). “Emergent Behavior in Biological Systems”, *Complexity International*, Volume 1, School of Environmental and Information Science, Charles Sturt University, Australia. URL: <http://www.csu.edu.au/ci/>
- GREGER, R. & WINDHORST, U. (1996). *Comprehensive Human Physiology* (Vols. 1 and 2).
- GUYTON, A. C. & HALL, J. E. (1996). *Textbook of Medical Physiology*, 9th ed., W. B. Saunders Company, Philadelphia.
- GUYTON, A. C. & HALL, J. E. (2002). *Tratado de Fisiologia Médica*, 10a edição, Editora Guanabara Koogan S.A., Rio de Janeiro, RJ.
- HAKEN, H. (1996). *Principles of Brain Functioning: A Synergetic Approach to Brain Activity, Behavior and Cognition*, Springer Series in Synergetics, Berlin, Alemanha.
- HAKEN, H. (2000). *Information and Self-organization: A Macroscopic Approach to Complex Systems*, 2a ed., Springer Series in Synergetics, Berlin, Alemanha.
- HALL, M. & HALLIDAY, T. (EDS.) (1998). *Behaviour and Evolution, Biology: Brain and Behaviour Series*, The Open University, Springer-Verlag.
- HALLIDAY, D., RESNICK, R. & WALKER, J. (2004). *Fundamentals of Physics*, Wiley, 7a edição.
- HAYKIN, S. (1999). *Neural Networks: A Comprehensive Foundation*, 2nd Ed., Prentice Hall.
- HEYLIGHEN, F. (1992). "Principles of Systems and Cybernetics: An Evolutionary Perspective", *Cybernetics and Systems '92*, R. Trappl (ed.), (World Science, Singapore), pp. 3-10.
- HEYLIGHEN, F. (1997). “Self-Organization”, em F. Heylighen, C. Joslyn and V. Turchin (editors): *Principia Cybernetica Web* (Principia Cybernetica, Brussels), URL: <http://pespmc1.vub.ac.be/SELFORG.html>

- HEYLIGHEN, F., BOLLEN, J. & RIEGLER, A. (EDS.) (1999). "The Evolution of Complexity", Kluwer Academic, Dordrecht.
- HOLLAND, J. H. (1986). "Escaping Brittleness: The Possibilities of General-Purpose Learning Algorithms Applied to Parallel Rule-Based Systems", em R.S. Michalski, J.G. Carbonell & T.M. Mitchell (eds.). Machine Learning: An Artificial Intelligence approach, Vol II, Los Altos, CA: Morgan Kaufman, pp. 593-623.
- HOLLAND, J. H. (1990). "Considering the Emergence of Tag-Mediated Lookahead in Classifier Systems", Physica D, Vol. 42, pp. 188-201.
- HOLLAND, J. H. (1992). Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence. The MIT Press, Ann Arbor, MI.91.
- HOLLAND, J. H. (1995). Hidden Order: How Adaptation Builds Complexity. Addison-Wesley, Inc.
- HOLLAND, J. H. (1998). Emergence: From Chaos to Order. Addison-Wesley, Inc.
- HOLLAND, O. & MELHUISE, C. (1999). "Stigmergy, Self-Organization, and Sorting in Collective Robotics", Artificial Life, 5(2), pp. 173-202.
- HOLMES, J. H. (1997). "Discovering Risk of Disease with a Learning Classifier System", URL: <http://cceb.med.upenn.edu/holmes/icga97.ps.gz>, ICGA97.
- HOLMES, J. H., LANZI, P. L., STOLZMANN, W., & WILSON, S. W. (2000). "Learning classifier systems: new models, successful applications", Information Processing Letters.
- HÖLSCHER, C. (1997), "Nitric Oxide, the enigmatic neuronal messenger: its role in synaptic plasticity", Trends Neuroscience 20, 298-303.
- HONDERICH, T. (ED.) (1995). The Oxford Companion to Philosophy, Oxford University Press.
- HOPFIELD, J. J. (1982). "Neural Networks and Physical Systems with Emergent Collective Computational Abilities". Proceedings of the National Academy of Sciences of the U.S.A.

79, pp. 2554-2558.

JANEWAY, C. A., P. TRAVERS, WALPORT, M. & CAPRA, J. D. (2000). *Imunobiologia: O Sistema Imunológico na Saúde e na Doença*, Artes Médicas, 4a Ed.

JEFRESS, L. (ED.) (1967). *Cerebral Mechanisms of Behavior*, Hafner, New York, 1967, p. 1.

JERNE, N. K. (1974). "Towards a Network Theory of the Immune System", *Ann. Immunol. (Int. Pasteur)* 125C, pp. 373-389.

JOHNSON, S. (2001). "Emergence: The Connected Lives of Ants, Brains, Cities and Software", Penguin Books, England.

KAPITANIAK, T. (1990). *Chaos in Systems with Noise*, Second Edition, World Scientific.

KAUFFMAN, S. (1993). *The Origins of Order*, Oxford University Press, Oxford.

KAUFFMAN, S. (1995). *At Home in the Universe: The Search for the Laws of Self-Organization and Complexity*, Oxford University Press.

KLOPF, A. H. (1982). *The Hedonistic Neuron: a Theory of Memory, Learning, and Intelligence*, Washington: Hemisphere.

KOHONEN, T. (1997). *Self-Organizing Maps*, 2nd. edition, Springer.

KONDEPUDI, D. & PRIGOGINE, I. (1998). *Modern Thermodynamics : From Heat Engines to Dissipative Structures*. John Wiley & Sons.

KOVACS, T. & LANZI, P.L. (1999). "A Learning Classifier Systems Bibliograph", Technical Report: CSRP-99-19, University of Birmingham, United Kingdom. URL: <http://www.cs.bris.ac.uk/~kovacs/lcs/search.html>.

KOVACS, T. (2000). "A Learning Classifier Systems Bibliograph". <http://www.cs.bris.ac.uk/~kovacs/lcs/search.html>

KOZA, J. R. (1992). *Genetic Programming: on the Programming of Computers by Means of Natural Selection*. The MIT Press, Cambridge, Massachusetts.

- KRIPPENDORFF, K. (1986). "A Dictionary of Cybernetics", unpublished report.
- KRUISBEEK, A. M. (1995). "Tolerance", *The Immunologist*, 3/5-6, pp. 176-178.
- K-TEAM S.A. (2005). URL: <http://www.k-team.com>, fornece informações adicionais sobre o robô Khepera II.
- LANGTON, C. G. (1990). "Computation at the Edge of Chaos: Phase Transitions and Emergent Computation", *Physica D*, 42, 1-3, pp. 12-37.
- LANGTON, C. G. (ED.) (1995). *Artificial Life - An Overview*, The MIT Press.
- LANZI, P. L., STOLZMANN, W. & WILSON, S. W. (EDS.) (2000). *Learning Classifier Systems. From Foundations to Applications*, volume 1813 of LNAI. Springer-Verlag, Berlin.
- LANZI, P. L., STOLZMANN, W. & WILSON, S. W. (EDS.) (2001). *Advances in Learning Classifier Systems*, volume 1996 of LNAI. Springer-Verlag, Berlin.
- LEVINE, D. S. (1998). *Explorations in Common Sense and Common Nonsense*, on-line book, url: <http://www.uta.edu/psychology/faculty/levine/EBOOK/index.htm>.
- LEVY, S. (1992). *Artificial Life – A Report from the Frontiers where Computers Meet Biology*, Vintage Books.
- LI, T. & YORKE, J. (1975). "Period three implies chaos", *American Mathematical Monthly* 82, 985-992.
- LOVELOCK, J. E. (1995). *The Ages of Gaia: A Biography of Our Living Earth*, Commonwealth Fund Book Program Series.
- LUCAS, C. (2003). "Self-Organization & Entropy – The Terrible Twins", CALResCo (Complexity & Artificial Life Research Concept) Organization, electronic report, URL: <http://www.calresco.org/extropy>
- LUENBERGER, D. G. (1979). *Introduciton to Dynamic Systems*, John Wiley & Sons, Inc.
- MATURANA, H. R. & VARELA, F. J. (1987). *The Tree of Konowledge – The Biological Roots of*

Human Understanding, New Science Library, Shambala Publications, Boston.

MCCLELLAND, J. L., RUMELHART, D. E. & THE PDP RESEARCH GROUP (1986). “Parallel Distributed Processing: Explorations in the Microstructure of Cognition”, Volume 2: Psychological and Biological Models, The MIT Press.

MCCCLINTIC, J. R. (1975). Basic Anatomy and Physiology of the Human Body, John Wiley & Sons, Inc., USA.

MCCCLINTIC, J. R. (1985). Physiology of the Human Body, 3rd ed., John Wiley & Sons, Inc., USA.

MICHALEWICZ, Z. & FOGEL, D. B. (2000). How to Solve It: Modern Heuristics. Springer-Verlag Berlin Heidelberg, New York.

MICHALEWICZ, Z. (1996). Genetic Algorithms + Data Structures = Evolution Programs. Springer-Verlag Berlin Heidelberg, New York.

MICHELAN, R. & VON ZUBEN, F.J. (2002). “Decentralized Control System for Autonomous Navigation based on an Evolved Artificial Immune Network”. Proceedings of the 2002 Congress on Evolutionary Computation (CEC'2002), vol. 2, pp. 1021-1026, Workshop on Artificial Immune Systems in the 2002 IEEE World Congress on Computational Intelligence (WCCI'2002), Honolulu, Hawaii, May 12-17.

MICHELAN, R. (2003). Evolução de Redes Imunológicas para Coordenação Automática de Comportamentos Elementares em Navegação Autônoma de Robôs, Tese de Mestrado, DCA, FEEC, Unicamp.

MINSKY, M. L. (1988). The Society of Mind, Touchstone Ed., Simon & Schuster Inc., NY.

NEAL, M. & TIMMIS, J. (2003). “Timidity: A Useful Mechanism for Robot Control?” Informatica, Vol. 27, No. 4, pp. 197-204.

NICOLIS, G. & PRIGOGINE, I. (1977). Self-Organization in Non-Equilibrium Systems, Wiley.

NICOLIS, G. & PRIGOGINE, I. (1989). Exploring Complexity: An Introduction. W.H. Freeman and

Company, NY, USA.

NILSSON, J. N. (1980). Principles of Artificial Intelligence, Morgan Kaufmann Pub. Inc..

NOLFI, S. & FLOREANO, D. (2000). Evolutionary Robotics: The Biology, Intelligence, and Technology of Self-Organizing Machines, The MIT Press.

O'REILLY, R. C. & MUNAKATA, Y. (2000). Computational Explorations in Cognitive Neuroscience: Understanding the Mind by Simulating the Brain, The MIT Press.

OGATA, K. (2001). Modern Control Engineering, 4<sup>th</sup> Edition, Prentice Hall.

OTT, E. (1991). Chaos in Dynamical Systems, Cambridge University Press.

PAUN, GH. (2002). Computing with Membranes: An Introduction. Springer-Verlag, Berlin.

PAUN, GH., ROZENBERG, G. & SALOMAA, A. (1998). DNA Computing. New Computing Paradigms, Springer-Verlag, Berlin

PEAK, D. & FRAME, M. (1998). Chaos under Control. The Art and Science of Complexity, 3a ed., W. H. Freeman and Company, New York.

PERELSON, A. S. & OSTER, G. F. (1979). "Theoretical Studies of Clonal Selection: Minimal Antibody Repertoire Size and Reliability of Self-Nonself Discrimination", J. theor.Biol., 81, pp. 645-670.

PERRETTA, S. J. & GALLAGHER, J. C. (2003). WSU Khepera Simulator, Wright State University, URL: <http://ehrg.cs.wright.edu/ksim/ksim/ksim.html>.

PFEIFER, R. & SCHEIER, C. (1999). Understanding Intelligence, MIT Press.

POOLE, D., MACKWORTH, A. & GOEBEL, R. (1998). Computational Intelligence: A Logical Approach, Oxford University Press, New York.

PURVES W. K., HELLER, H. C, ORIAN, G. H. & SADAVA, D. (2001). Life: The Science of Biology, 6th Edition, IE-Macmillan UK.

RICHARDS, D. (1990). "Is Strategic Decision Making Chaotic?", Behavioral Science, vol. 35, pp.

219-232.

- RICHARDS, R. A. (1995). Zeroth-Order Shape Optimization utilizing Learning Classifier Systems. Tese de Doutorado, Universidade de Stanford.  
<http://www.stanford.edu/~buc/SPHINcsX/book.html>.
- RUMELHART, D. E., MCCLELLAND, J. L. & THE PDP RESEARCH GROUP (1986). "Parallel Distributed Processing: Explorations in the Microstructure of Cognition", Volume 1: Foundations, The MIT Press.
- RUSSELL, S. J. & NORVIG, P. (1995). Artificial Intelligence: A Modern Approach, Prentice Hall.
- SCHMID, G.B. (1991). "Chaos Theory and Schizophrenia: Elementary Aspects", Psychopathology, vol. 24, pp. 185-198.
- SHU, L. & SCHAEFFER, J. (1989). "VCS: Variable Classifier System", ICGA89, pp. 334-339.
- SIPPER, M. (2002). Machine Nature: The Coming Age of Bio-Inspired Computing, McGraw-Hill, New York, 2002.
- STOLZMANN, W. (1996). "Learning Classifier Systems using the Cognitive Mechanism of Anticipatory Behavioural Control, detailed version.", Proceedings of the First European Workshop on Cognitive Modeling, Berlin, pp. 82-89.
- SUTTON, R. S. & BARTO, A. G. (1998). Reinforcement Learning: An Introduction, The MIT Press.
- SUTTON, R. S. & BARTO, A. G. (1998). Reinforcement Learning: An Introduction, "Adaptive Computation and Machine Learning", The MIT Press.
- SWENSON, R. (1989). "Emergent Attractors and the Law of Maximum Entropy Production: Foundations to a Theory of General Evolution", Systems Research 6:3, p. 187-198.
- TAKADAMA, K., TERANO, T., SHIMOHARA, K., HORI, K. & NAKASUKA, S. (1999). "Making Organizational Learning Operational: Implications from Learning Classifier System, Computational and Mathematical Organization Theory (CMOT)", Kluwer Academic

Publishers, Vol. 5, No. 3, pp. 229-252.

THAGARD, P. (1996). *Mind: Introduction to Cognitive Science*, The MIT Press, USA.

THELEN, E. & SMITH, L.B. (1994). "A Dynamic Systems Approach to the Development of Cognition and Action", The MIT Press.

THOMAS, N. J. T. (1997). "A Stimulus to the Imagination: A Review of Questioning Consciousness: The Interplay of Imagery, Cognition and Emotion in the Human Brain by Ralph D. Ellis", *PSYCHE*, 3(4).

TIMMIS, J. & NEAL, M. (2004). "Once More Unto the Breach: Towards Artificial Homeostasis", Capítulo XIV do livro *Recent Developments in Biologically Inspired Computing*. Organizado por L.N. de Castro & F.J. Von Zuben, pp. 340-366.

TOMLINSON, A. & BULL, L. (1999). "On Corporate Classifier Systems: Increasing the Benefits of Rule Linkage", *GECCO99*, pp. 649-656.

TRAPPENBERG, T. (2002). *Fundamentals of Computational Neuroscience*, Oxford University Press.

VAN GEERT, P. (1991). "A Dynamic Systems Model of Cognitive and Language Growth", *Psychological Review*, vol. 98, pp. 3-53.

VAN GELDER, T. & PORT, R. (1995). "It's About Time: An Overview of the Dynamical Approach to Cognition", in Port, R. & van Gelder, T. (eds.) *Mind as emotion: Explorations in the dynamics of cognition*, The MIT Press, pp. 1-43.

VAN GELDER, T. (1995). "What Might Cognition Be, If Not Computation?", *Journal of Philosophy*, vol. 92, pp. 345-381.

VARGAS, P. A. (2000). *Sistemas Classificadores para Redução de Perdas em Redes de Distribuição de Energia Elétrica*, Tese de Mestrado, DENSIS/DCA – FEEC/Unicamp, Campinas/SP, Brasil, 98 páginas, Outubro, 2000.

VARGAS, P. A., DE CASTRO, L. N. & VON ZUBEN, F. J. (2002). "Artificial Immune Systems as

Complex Adaptive Systems” in Proceedings of the First International Conference on Artificial Immune Systems-ICARIS-2002, pp. 115-123.

VARGAS, P. A., DE CASTRO, L. N. & VON ZUBEN, F. J. (2002). “Mapping Artificial Immune Systems into Learning Classifier Systems”, Fifth International Workshop on Learning Classifier Systems (IWLCS-2002) at PPSN-2002, published on a special issue of Lecture Notes in Artificial Intelligence (LNAI 2661), Springer-Verlag, pp. 163-186.

VARGAS, P. A., DE CASTRO, L.N., MICHELAN, R. & VON ZUBEN, F. J. (2003a). Implementation of an Immuno-Genetic Network on a Real Khepera II Robot. Proceedings of the Congress on Evolutionary Computation-CEC-2003, Special Session on Artificial Immune Systems, held in Canberra, Australia, December 8-12, 2003, pp. 420-426.

VARGAS, P. A., DE CASTRO, L.N., MICHELAN, R. & VON ZUBEN, F. J. (2003b). An Immune Learning Classifier Network for Autonomous Navigation. Lecture Notes in Computer Science (LNCS 2787), Special Issue on Artificial Immune Systems, Proceedings of the Second International Conference on Artificial Immune Systems (ICARIS-2003), Springer-Verlag, pp. 69-80.

VARGAS, P. A., GUDWIN, R., DE CASTRO, L. N. & VON ZUBEN, F. J. (2001). “A Semiotic Analysis of Neuro-Immune-Endocrine Interactions”, Relatório Técnico, RT DCA/02.2001, Julho, 2001, DCA/FEEC/Unicamp.

VARGAS, P. A., LYRA, C. & VON ZUBEN, F. J. (2004). Application of Learning Classifier Systems to the On Line Reconfiguration of Electric Power Distribution Networks, capítulo em Larry Bull (editor), Applications of Learning Classifier Systems, pp. 260-275. Springer Series: Studies in Fuzziness and Soft Computing, Vol. 150, VIII, 305 p., Hardcover. ISBN: 3-540-21109-8.

VARGAS, P.A., MOIOLI, R., DE CASTRO, L. N., TIMMIS, J., NEAL, M., & VON ZUBEN, F., (2005). “Artificial Homeostatic System: a Novel Approach”, Proceedings of the ECAL'2005 - VIIIth European Conference on Artificial Life, University of Kent, Canterbury, Kent UK, September 2005.

- VARGAS, P.A., ROCKS, C., TIMMIS, J., NEAL, M., DE CASTRO, L. N. & VON ZUBEN, F. (2004). "Artificial Endocrine System: A Novel Approach", Technical Report RTDCA/01.2004, LBiC, DCA, UNICAMP, Brasil.
- VELLASCO, M. M. B. R. (2004). "Sistemas Neuro-Fuzzy", Slides de Apresentação, Núcleo de Pesquisa em Inteligência Computacional Aplicada (ICA-PUC-Rio).
- VON BERTALANFFY, L. (1968). *General System Theory*. Braziller.
- VON FOERSTER, H. (1960). "On Self-Organizing Systems and their Environments", *Self-Organizing Systems*, Yovitts M. & Cameron S. (ed.), (Pergamon, New York), pp.31-50.
- WALDROP, M. M. (1993). *Complexity: The Emerging Science at the Edge of Order and Chaos*, Touchstone Ed., New York, USA.
- WATANABE, Y., ISHIGURO, A. & UCHIKAWA, H. (1999). "Decentralized Behaviour Arbitration Mechanism for Autonomous Mobile Robot Using Immune Network", In D. Dasgupta (Editor), *Artificial Immune Systems and their Applications*, Springer.
- WATANABE, Y., ISHIGURO, A., SHIRAI, Y. & UCHIKAWA, Y. (1998). "Emergent Construction of Behavior Arbitration Mechanism Based on the Immune System", *Proc. of ICEC'98*, pp.481-486.
- WEISBUCH, G. (1997). "Complex Systems Dynamics: an Introduction to Automata Networks", *Santa Fe Institute Studies in the Sciences of Complexity, Lecture Notes, vol. 2*, Addison-Wesley Pub. Company, 5th printing.
- WILCOX, J. R. (1995). "Organisational Learning within a Learning Classifier System", *University of Illinois*, Technical Report No. 95003 IlliGAL.
- WILLIAMS, G.P. (1999). *Chaos Theory Tamed*, Joseph Henry Press, Washington, DC, USA.
- WILSON, S. W. (1994). "ZCS: A Zeroth Level Classifier System", *Evolutionary Computation*, 1, Vol. 2, pp. 1-18.
- WILSON, S. W. (1995). "Classifier Fitness Based on Accuracy", *Evolutionary Computation*, 2,

Vol. 3, pp.149-175.

ZHOU, H. H. (1985). “Classifier Systems with Long Term Memory”, ISBN = 0-8058-0426-9, ICGA85, pp. 178-182.

# APÊNDICE

## TABELA DE ACRÔNIMOS

ACS – anticipatory classifier system

AG - algoritmos genéticos

CCS – corporate classifier system

CE - computação evolutiva

CGP's - constrained generating procedures

CLARINet - rede imunológica de classificadores (CLAssifieR Immune Network)

CPH - controlador de produção de hormônios

CS - classifier system

CSM - classifier system with memory

EE - estímulo externo

EI - estado interno

EUD - estrutura unificada de descrição

FCS - fuzzy classifier system

GE - glândula endócrina

HCS – hierarchical classifier system

HP - produção de hormônio

IA	- inteligência artificial
IB	- inteligência biológica
IC	- inteligência computacional
LBiC	- Laboratório de Bioinformática e Computação Bio-Inspirada
LCS	- learning classifier systems
MLP	- multi-layer perceptron
NH	- nível hormonal
OCS	- organizational classifier system
PCS	- predictive classifier system
PICS	- pittsburgh immune classifier system
QE	- quantidade de energia
RNA	- redes neurais artificiais
SB	- sistemas biológicos
SC	- sistemas classificadores com aprendizado
SC	- sistemas complexos
SCA	- sistemas complexos artificiais
SCB	- sistemas computacionais bio-inspirados
SCD	- sistemas complexos adaptativos
SCN	- sistemas complexos naturais
SCNB	- sistemas computacionais não bio-inspirados
SCNO	- sistemas complexos não-organizados

SCO - sistemas complexos organizados

SCS - simple classifier system

SE - sistema endócrino

SEA - sistemas endócrinos artificiais

SHA - sistemas homeostáticos artificiais

SHN - sistemas homeostáticos naturais

SI - sistema imunológico

SIA - sistemas imunológicos artificiais

SIC - sistemas de inteligência computacional

SN - sistema nervoso

SNB - sistemas não-biológicos

VCS – variable classifier system

XCS - special classifier system

ZCS - zeroth-level classifier system

## ÍNDICE REMISSIVO DE AUTORES

ADLEMAN, L.M., **2**.

ANDERSSON, N., BROBERG, A., BRÄNBERG, A., JANLERT, L., JONSSON, E., HOLMLUND, K. & PETTERSSON, J., **22**.

ATMAR, W., **65**.

AXELROD, R., **84**.

BÄCK, T., FOGEL, D. B. & MICHALEWICZ, Z., **67**.

BAK, P., **24, 36**.

BARTON, S., **7**.

BERDICHEVSKY, V. L., **18**.

BESENOVSKY, H. O. & DEL REY, A., **36, 45, 58, 109**.

BEZDEK, J. C., **62**.

BLICKLE, T., **67**.

BOOKER, L. B., GOLDBERG, D. E. & HOLLAND, J. H., **68**.

BROOKS, R., **92, 126**.

BURNET, F. M., **42, 52**.

BUSEMEYER, J.R. & TOWNSEND, J.T., **6**.

BUSHEV, M., **4, 29, 35**.

CAETANO, F. H., JAFFÉ, K. & ZARA, F. H., **31, 33**.

- CAMAZINE, S., DENEUBOURG, J.-L., FRANKS, N.R., SNEYD, J., THERAULAZ, G. & BONABEAU, E.,  
**21.**
- CANNON, W. B., **37.**
- CAZANGI, R. R., **108, 162.**
- CHAITIN, G., **12.**
- CHURCHLAND, P. & SEJNOWSKI, T.J., **7, 40.**
- COHEN, J. & STEWART, I., **20.**
- COPELAND, J. & PROUDFOOT, D., **2.**
- COVENEY, P. & HIGHFIELD, R., **1, 11, 12, 13, 18, 24, 36.**
- COWAN, G., PINES, D & MELTZER, D., **12.**
- DARWIN, C., **23, 36, 65.**
- DASGUPTA, D., **51.**
- DAYAN, P. & ABBOT, L. F., **7, 40.**
- DE CASTRO, L. N. & TIMMIS, J., **42, 46, 51, 52, 56, 82, 91.**
- DE CASTRO, L. N., **2, 91.**
- DE CASTRO, L.N. & VON ZUBEN, F. J., **2, 3.**
- DE ROSNAY, J., **19, 21.**
- DEJONG, K., **67.**
- DENBIGH, K. G., **19, 20, 21.**
- DORIGO, M. & COLOMBETTI, M., **127, 159, 160**
- ELOWITZ, M. B. & LEIBLER, S. M., **2.**
- FARMER, J. D., **5, 82, 84.**

FARMER, J. D., PACKARD, N. H. & PERELSON, A. S., **52, 82, 83, 86, 88.**

FAUSETT, L., **40.**

FERREIRA, A. B. H., **37.**

FOGEL, D. B., **29, 30, 64.**

FORBES, N., **2, 3.**

FORREST, S., **23.**

FURUHASHI, T., NAKAOKA, K. & UCHIKAWA, Y., **76.**

GALLAGHER, R. & APPENZELLER, T., **23, 36.**

GALLY, J. A., MONTAGUE, P. R., REEKE, G. N. JR & EDELMAN, G. M., **39.**

GARDNER, H., **61.**

GARDNER, T.S., **2.**

GASPAR, A. & HIRSBRUNNER, B., **82, 83.**

GOLDBERG, D. E., **65, 66, 67, 76.**

GOLDENFELD, N. & KADANOFF, L. P., **13.**

GOODWIN, B., **24.**

GRASSÉ, P. P., **64.**

GREEN, D. G., **22.**

GREGER, R. & WINDHORST, U., **41, 110, 113.**

GUYTON, A. C. & HALL, J. E., **39, 40, 45, 110, 112, 125.**

HAKEN, H., **29, 30.**

HALL, M. & HALLIDAY, T., **2.**

- HALLIDAY, D., RESNICK, R. & WALKER, J., **18**.
- HAYKIN, S., **6, 40, 48, 49, 114, 118, 137**.
- HEYLIGHEN, F., **18, 20, 21**.
- HEYLIGHEN, F., BOLLEN, J. & RIEGLER, A., **171**.
- HOLLAND, J. H., **21, 22, 29, 30, 32, 61, 63, 65, 66, 68, 72, 76, 77, 160**.
- HOLLAND, O. & MELHUIH, C., **64**.
- HOLMES, J. H., **77**.
- HOLMES, J. H., LANZI, P. L., STOLZMANN, W., & WILSON, S. W., **78, 79**.
- HÖLSCHER, C., **39**.
- HONDERICH, T., **18**.
- HOPFIELD, J. J., **7**.
- JANEWAY, C. A., P. TRAVERS, WALPORT, M. & CAPRA, J. D., **41**.
- JEFRESS, L., **2**.
- JERNE, N. K., **43, 52, 83, 86**.
- JOHNSON, S., **22**.
- KAPITANIAK, T., **18**.
- KAUFFMAN, S., **20, 23, 24**.
- KLOPF, A. H., **37**.
- KOHONEN, T., **102**.
- KONDEPUDI, D. & PRIGOGINE, I., **19**.
- KOVACS, T. & LANZI, P.L., **76**.

- KOVACS, T., **76**.
- KOZA, J. R., **67**.
- KRIPPENDORFF, K., **17, 19**.
- KRUISBEEK, A. M., **52**.
- K-TEAM S.A., **127**.
- LANGTON, C. G., **1, 18, 24**.
- LANZI, P. L., STOLZMANN, W. & WILSON, S. W., **76**.
- LEVINE, D. S., **37**.
- LEVY, S., **19, 20, 21**.
- LI, T. & YORKE, J., **17**.
- LOVELOCK, J. E., **20**.
- LUCAS, C., **21**.
- LUENBERGER, D. G., **15**.
- MATURANA, H. R. & VARELA, F. J., **41**.
- MCCLELLAND, J. L., RUMELHART, D. E. & THE PDP RESEARCH GROUP, **40**.
- MCCLINTIC, J. R., **37, 39**.
- MICHALEWICZ, Z. & FOGEL, D. B. , **29, 30**.
- MICHALEWICZ, Z., **66, 67, 72**.
- MICHELAN, R. & VON ZUBEN, F.J., **94, 95, 106**.
- MICHELAN, R., **91, 92, 94, 107, 162**.
- MINSKY, M. L., **61**.

- NEAL M. & TIMMIS J., **114, 116.**
- NICOLIS, G. & PRIGOGINE, I., **11, 14, 23, 36.**
- NILSSON, J. N., **1.**
- NOLFI, S. & FLOREANO, D. , **127, 160.**
- O'REILLY, R. C. & MUNAKATA, Y., **7, 40.**
- OGATA, K., **119.**
- OTT, E., **16.**
- PAUN, GH., **2.**
- PAUN, GH., ROZENBERG, G. & SALOMAA, A., **2.**
- PEAK, D. & FRAME, M., **17, 22.**
- PERELSON, A. S. & OSTER, G. F., **51.**
- PERRETTA, S. J. & GALLAGHER, J. C., **126, 137, 144.**
- PFEIFER, R. & SCHEIER, C., **6, 37, 61, 92, 93.**
- POOLE, D., MACKWORTH, A. & GOEBEL, R., **63.**
- PURVES W. K., HELLER, H. C, ORIAN, G. H. & SADAVA, D., **1, 2, 38, 39, 40, 45, 46, 110, 111, 117.**
- RICHARDS, D., **6.**
- RICHARDS, R. A., **70, 159.**
- RUMELHART, D. E., MCCLELLAND, J. L. & THE PDP RESEARCH GROUP, **40.**
- RUSSELL, S. J. & NORVIG, P., **1.**
- SCHMID, G.B., **7.**
- SHU, L. & SCHAEFFER, J., **76.**

SIPPER, M., **2, 3, 162.**

STOLZMANN, W., **77, 79.**

SUTTON, R. S. & BARTO, A. G., **49, 90.**

SWENSON, R., **20.**

TAKADAMA, K., TERANO, T., SHIMOHARA, K., HORI, K. & NAKASUKA, S., **77.**

THAGARD, P., **6, 15.**

THELEN, E. & SMITH, L.B., **7.**

THOMAS, N. J. T., **94.**

TIMMIS, J. & NEAL, M., **55, 113, 114, 116, 117, 118, 120, 137.**

TOMLINSON, A. & BULL, L., **77.**

TRAPPENBERG, T., **7.**

VAN GEERT, P., **6.**

VAN GELDER, T. & PORT, R., **7, 94.**

VAN GELDER, T., **7, 94.**

VARGAS, P. A., **71, 73, 74, 75, 83, 160.**

VARGAS, P. A., DE CASTRO, L. N. & VON ZUBEN, F. J., **51, 79, 83, 84, 106, 160.**

VARGAS, P. A., GUDWIN, R., DE CASTRO, L. N. & VON ZUBEN, F. J., **116.**

VARGAS, P. A., LYRA, C. & VON ZUBEN, F. J., **79, 83.**

VARGAS, P.A., ROCKS, C., TIMMIS, J., NEAL, M., DE CASTRO, L. N. & VON ZUBEN, F., **129.**

VARGAS, P. A., DE CASTRO, L.N., MICHELAN, R. & VON ZUBEN, F. J., **92, 108.**

VARGAS, P.A., MOIOLI, R., DE CASTRO, L. N., NEAL, M., TIMMIS, J., & VON ZUBEN, F., **155.**

VELLASCO, M. M. B. R., **4.**

VON BERTALANFFY, L., **12, 14.**

VON FOERSTER, H., **19, 21.**

WALDROP, M. M., **23.**

WATANABE, Y., ISHIGURO, A. & UCHIKAWA, H., **93, 160.**

WATANABE, Y., ISHIGURO, A., SHIRAI, Y. & UCHIKAWA, Y., **94, 160.**

WEISBUCH, G., **14.**

WILCOX, J. R., **77.**

WILLIAMS, G.P., **22.**

WILSON, S. W., **77, 78.**

ZHOU, H. H., **76.**