

1 Introdução

1.1 Motivação

A concepção de sistemas artificiais inspirados na natureza não é uma idéia recente. As Redes Neurais Artificiais, a Computação Evolucionária, o Enxame de Partículas e as Colônias de Formigas são alguns exemplos de técnicas utilizadas em aplicações bem sucedidas de metáforas biológicas empregadas na solução de problemas nas áreas de Engenharia e da Ciência da Computação.

O estudo de Sistemas Imunológicos Artificiais é relativamente recente e procura explorar mecanismos que são utilizados nos Sistemas Imunológicos encontrados na natureza com o objetivo de desenvolver técnicas de solução de problemas.

O Sistema Imunológico é um dos sistemas mais complexos que existem na natureza e sua complexidade pode ser comparada à do Sistema Nervoso (Varela et al., 1988). A principal função do Sistema Imunológico é fornecer proteção ao organismo contra uma infinidade de agentes patogênicos (vírus, bactérias, moléculas estranhas, etc)(Hofmeyr, 1997). A grande diversidade de agentes patogênicos que deve ser combatida torna esta tarefa extremamente difícil e exige que o Sistema Imunológico utilize uma variedade de mecanismos que se completam e se sobrepõem, tornando-o bastante complexo. De fato, muitos destes mecanismos ainda hoje não são totalmente compreendidos (Janeway, 1993). Por outro lado, esta complexidade pode ser uma fonte de inspiração bastante frutífera para a computação inspirada na natureza.

O Sistema Imunológico pode ser dividido em duas partes: o sistema inato e o sistema adaptativo (Castro & Timmis, 2002d). Quando o organismo é invadido por um agente patogênico, o sistema inato é o primeiro a entrar em ação. Sua resposta não é específica mas em muitos casos é capaz de proteger o organismo. Se isto não acontecer, então o sistema adaptativo entra em ação. A ação do sistema adaptativo é mais específica, o que resulta em uma resposta mais eficaz.

Do ponto de vista da Ciência da Computação, o sistema adaptativo é a parte mais interessante do Sistema Imunológico (Castro, 2001a). O Sistema Imunológico adaptativo pode recordar encontros passados com agentes patogênicos, de modo que, quando houver uma nova aparição deste agente, uma reação mais específica e eficaz ocorrerá. Isto é denominado de memória imunológica (Kuby, 1997). Um outro mecanismo interessante é o reconhecimento *próprio/não-próprio* (Forrest et al., 1994). O Sistema Imunológico é capaz de distinguir células (proteínas) que são *próprias* do organismo daquelas que não o são. Deste modo, ele é capaz de atacar o agente patogênico e não o próprio organismo.

De um modo geral, os Sistemas Imunológicos Artificiais podem ser classificados em três categorias principais: os inspirados na teoria de redes imunológicas, os que são baseados no princípio da Seleção Clonal e os que utilizam técnicas inspiradas no mecanismo de reconhecimento *próprio/não-próprio*.

Em um dos primeiros trabalhos a sugerir que o Sistema Imunológico poderia servir de inspiração para um modelo computacional (Farmer et al., 1986), foi proposto um modelo para reconhecimento de padrões baseado na teoria da rede idiotípica (Jerne, 1974), que procura explicar o mecanismo da rede imunológica. Foi mostrado que o Sistema Imunológico pode ser visto como um sistema que é capaz de aprender e que pode ser usado como inspiração para técnicas de *machine learning*. Estas idéias foram aprimoradas (Cook & Hunt, 1995) para desenvolver um algoritmo para classificação de seqüências de DNA. Mais tarde, Timmis (Timmis, 2000b) modificou o algoritmo para desenvolver uma técnica geral de clusterização.

O princípio da Seleção Clonal (Castro, 2001b) descreve as características básicas de uma resposta imunológica a um estímulo antigênico. Ele estabelece que apenas as células que reconhecem o antígeno são selecionadas para proliferar. A Teoria da Seleção Clonal prevê a geração de células filhas (clones) sujeitas a um processo de hipermutação somática, sendo que as células com receptores que reagem com as proteínas do próprio organismo são eliminadas.

O Algoritmo de Seleção Negativa (*NSA – Negative Selection Algorithm*) (Forrest et al., 1994) é inspirado no mecanismo usado pelo Sistema Imunológico para treinar células T a distinguir antígenos (*não-próprio*) das células do corpo

(*próprio*). A idéia básica é gerar um conjunto de detectores, primeiro gerando candidatos aleatoriamente e depois descartando aqueles que reconhecem os dados que são considerados *próprios*. Mais tarde, estes detectores podem ser usados para detectar anomalias. Diversas variações deste algoritmo foram aplicadas na detecção de intrusos (Dasgupta, 1999d), de anomalias (Dasgupta, 1996) e de falhas (Dasgupta, 1999d).

Mesmo considerando o sucesso dos Sistemas Imunológicos Artificiais nestas aplicações (tendo em vista que pertencem a uma área de estudos relativamente recente), diversos de seus aspectos requerem aprimoramento, dentre os quais podem ser citadas a representação dos detectores e a determinação de parâmetros que têm efeito sobre a eficiência dos algoritmos.

A representação dos detectores está relacionada ao estudo da representação real para o algoritmo de Seleção Negativa, pois atualmente uma boa parte das implementações do NSA utiliza representação binária. A representação real permite uma maior flexibilidade para a representação dos espaços *próprio/não-próprio*, o que pode tornar a extração de conhecimento mais simples. A representação real também viabiliza diferentes funções de afinidade ou detecção, e, portanto, pode ter influência direta na eficiência computacional.

A determinação de parâmetros dos detectores, como, por exemplo, seu posicionamento e raio de ação, certamente afetam a eficiência do sistema. Considerando-se a representação real, o posicionamento inicial dos detectores é feito de modo pseudo-aleatório e o raio de ação de cada um deles é determinado no início do processo, mantendo-se inalterado durante o aprendizado do sistema, isto é, durante o procedimento de posicionamento dos detectores, que é realizado através de regras heurísticas (Gonzalez, 2003). Assim, faz-se necessário pesquisar outros métodos para o aprendizado do posicionamento dos detectores, que possam aproveitar as vantagens de uma representação mais flexível e que possuam uma forma mais concreta de avaliar a eficiência do método no posicionamento dos detectores. Por fim, seria bastante proveitoso conceber um sistema capaz de determinar automaticamente o número de detectores necessários para um bom desempenho do sistema, utilizando, por exemplo, uma técnica de particionamento como o Quadtree (Smith & Chang, 1994).

É importante conceber novos modelos para geração de detectores para o Algoritmo de Seleção Negativa, com representação real, capazes de investigar

esses diversos aspectos, tendo em vista as aplicações relativas à detecção de falhas.

Em resumo, as motivações deste trabalho são o desenvolvimento de algoritmos relacionados com um novo modelo de Sistema Imunológico Artificial Híbrido, com ênfase na geração do conjunto de detectores, para aplicações em detecção de falhas.

1.2 Objetivos

A pesquisa realizada tem como objetivo principal o desenvolvimento de métodos de geração de detectores para aprimorar a função de detecção de falhas do algoritmo de Seleção Negativa. Isto implica na concepção de uma nova representação para os detectores que viabilize a determinação automática dos parâmetros fundamentais de cada detector, a saber, seu raio e sua posição. Além disso, é fundamental que a quantidade dos detectores possa ser determinada pelo método de modo consistente.

Cabe ressaltar que a busca deste objetivo principal enfoca diretamente a importante questão da escalabilidade, isto é, os métodos desenvolvidos visam a geração controlada do número de detectores.

Objetiva-se também mostrar a aplicabilidade das técnicas através do desenvolvimento de ambientes adequados para avaliação, permitindo a realização de diversas experiências para demonstrar suas potencialidades.

1.3 Contribuições da Tese

Os resultados desta tese contribuem para o desenvolvimento científico das áreas de ciência da computação e engenharia eletrônica, mais especificamente no projeto e implementação de Sistemas Imunológicos Artificiais, em particular daqueles que utilizam o Algoritmo de Seleção Negativa na área de detecção de falhas.

No projeto e implementação de Sistemas Imunológicos Artificiais é apresentada uma outra representação real para os detectores que são utilizados no Algoritmo de Seleção Negativa e são concebidos três modelos capazes de gerar

detectores de acordo com esta representação. Estes novos modelos são capazes de gerar detectores de forma bastante eficiente, o que representa um avanço significativo para o Algoritmo de Seleção Negativa, sobretudo no que se refere à escalabilidade. Além disso, esta nova forma de representação permite um maior avanço na integração dos Sistemas Imunológicos Artificiais com outros paradigmas, como, por exemplo, a integração do Algoritmo de Seleção Negativa com classificadores baseados em Redes Neurais.

A representação e os modelos utilizados constituem uma contribuição para o avanço da pesquisa na área de detecção de falhas utilizando sistemas inteligentes, uma vez que estes modelos permitem o uso de classificadores inteligentes com um melhor desempenho, sobretudo em situações onde se tem um pequeno número de exemplos representativos das falhas específicas.

1.4

Descrição do Trabalho

Esta tese apresenta três métodos para o desenvolvimento de sistemas de detecção de falhas fundamentados em Sistemas Imunológicos Artificiais. O projeto e a implementação dos sistemas são abordados.

Considerando-se que uma das propostas é desenvolver um sistema de detecção de falhas, inicialmente realizou-se um estudo sobre os fundamentos de detecção e diagnóstico de falhas pesquisando diversas técnicas, dentre as quais citam-se:

- Técnicas tradicionais de detecção de falhas, como sistemas baseados em regras (Rowland, 1993) e árvores de decisão de falhas (Juricic, 1997).
- Abordagens baseadas em Modelos (Fenton et al., 2001);
- Abordagens baseadas em Casos (*Case Based Reasoning* (Bergmann, 1998));
- Técnicas inteligentes, sobretudo aquelas baseadas em Lógica Fuzzy e Redes Neurais.

Nesta etapa, verificou-se que a utilização de técnicas inteligentes para a detecção de falhas estava baseada na construção de modelos e no uso de classificadores. No caso da construção de modelos, quando as relações entre as variáveis do sistema são difíceis de se estabelecer ou a quantidade de dados

disponível for limitada, o modelo extraído pode não ser suficientemente preciso para distinguir entre situações normais e de falha. (Martins et al, 2000).

Os classificadores, por sua vez, procuram por padrões de falha específicos, o que os torna vulneráveis quando têm que lidar com padrões de falhas diferentes dos previstos (Martins et al., 2000). Uma outra limitação importante é que em muitas situações existem muito poucos dados que representem condições de falha (Taylor & Corne, 2003).

Considerando-se estas dificuldades e recordando que o Sistema Imunológico tem a capacidade de distinguir qualquer célula estranha (*não-própria*) das células do corpo (*própria*), verificou-se que esta propriedade pode ser utilizada na detecção de falhas para discriminar os padrões normais de funcionamento do sistema de quaisquer padrões não toleráveis. Sendo assim, o trabalho prosseguiu, pesquisando um novo paradigma em Inteligência Computacional, os Sistemas Imunológicos Artificiais (Castro & Timmis, 2002). Esta pesquisa incluiu um estudo sobre o Sistema Imunológico Humano e dos três modelos principais utilizados nos Sistemas Imunológicos artificiais, que são:

- O algoritmo de Seleção Negativa;
- O Algoritmo de Seleção Clonal;
- Redes Imunológicas Artificiais;

Entre os modelos estudados, o Algoritmo de Seleção Negativa (NSA) é o de maior interesse para a área de detecção de falhas, pois é capaz de realizar a detecção utilizando apenas os padrões normais (*próprios*). Além disso, ele também pode ser usado para gerar amostras para treinamento de classificadores e com isso melhorar seu desempenho.

A idéia básica do NSA é gerar um conjunto de detectores, primeiro gerando candidatos aleatoriamente e depois descartando aqueles que reconhecem os dados que são considerados *próprios*. Mais tarde, estes detectores podem ser usados para detectar anomalias. Portanto, o NSA possui três fases: definição do que é *próprio*, geração dos detectores e monitoração de ocorrências de anomalias. Diversas variações deste algoritmo foram aplicadas na detecção de intrusos (Dasgupta, 1999d), de anomalias (Dasgupta, 1996) e de falhas (Dasgupta, 1999d).

Foram estudadas algumas técnicas utilizadas para gerar os detectores. Em particular, o método proposto por Dasgupta (Dasgupta, 1996), que gera detectores binários e utiliza a regra de detecção r bits contíguos, que não é aplicável

diretamente à detecção de falhas em problemas de engenharia, uma vez que ela não leva em conta o significado físico do processo que está sendo monitorado (Martins et al, 2000).

O outro método estudado foi o Algoritmo de Seleção Negativa com representação real (RNSA) (Gonzalez, et al, 2002), no qual os detectores são hipersferas cujos raios são fixos e determinados antes da execução do algoritmo de geração de detectores.

A representação real pode ser utilizada em uma série de aplicações. Mesmo que os dados não sejam números reais, muitas vezes é possível encontrar um mapeamento para o espaço real. Outros Algoritmos Imunológicos Artificiais utilizam este tipo de representação, como, por exemplo, as redes imunológicas e os algoritmos de seleção clonal (Castro & Timmis, 2002d). A utilização desta representação visa a facilitar a integração do NSA com outros paradigmas da Inteligência Computacional.

A partir deste estudo do RNSA foi concebido um algoritmo heurístico com representação real, o RNSA-LVQ (*Learning Vector Quantization*), baseado no RNSA, que utiliza um sistema de representação baseado em hipersferas de centro variável e raio fixo e com uma regra de aprendizado inspirada no LVQ (Kohonen, 1998).

A representação multidimensional do espaço *próprio/não-próprio* abre a possibilidade de definição de diferentes tipos de detectores. Nesta proposta, cada detector é representado por uma hipersfera representada por um ponto no \mathfrak{R}^n , que é o centro, e por um valor no \mathfrak{R}^+ , que é o raio de ação. Esta representação apresenta uma flexibilidade maior do que aquela vista em (Gonzalez et al, 2002) e (Amaral et al., 2004a), onde o valor do raio para todos os detectores é fixo. A utilização de diferentes raios para cada detector permite que a cobertura do espaço *não-próprio* seja feita com um menor número de detectores, possibilitando que este algoritmo seja utilizado em uma escala maior.

Para esta nova representação de detectores, foi necessário desenvolver novos modelos capazes de gerar detectores para cobrir o espaço próprio de forma eficiente, o que se constitui em uma tarefa bastante complexa (Gonzalez, 2003).

O primeiro modelo utiliza algoritmos genéticos para obter um conjunto de detectores que seja capaz de cobrir o espaço *não-próprio* de forma eficiente. Na representação utilizada, cada gene do cromossomo contém um índice para um

ponto de uma distribuição quasi-aleatória que servirá como centro do detector. Uma função decodificadora será responsável por determinar os raios apropriados. A aptidão do cromossomo é dada por uma estimativa do volume coberto pelo conjunto de detectores que ele representa. Esta estimativa é dada por uma integral de Monte Carlo.

O segundo modelo utiliza o particionamento Quadtree para gerar o posicionamento dos detectores e o valor dos raios. Este modelo pode realizar o particionamento a partir de uma função de detecção ou através de divisões recursivas de um detector inicial que ocupa todo o espaço.

O terceiro modelo é inspirado nas redes imunológicas. Neste modelo, as células B representam os detectores e a rede formada por eles dá a posição e o raio de cada detector. De acordo com o modelo de rede imunológica, os detectores podem estimular e inibir uns aos outros, de várias formas, até que a rede se estabilize, o que, neste caso, significa até que a distribuição dos detectores e seus raios estejam determinados.

Os estudos de casos foram divididos em duas partes principais. Na primeira parte, utilizaram-se exemplos bidimensionais para avaliar com maior facilidade as características de cada modelo proposto. Na segunda parte, são utilizados diversos exemplos de diferentes áreas.

1.5 Estrutura da Tese

O Capítulo 2 apresenta uma visão geral das diferentes abordagens utilizadas para a detecção e diagnósticos de falhas.

O Capítulo 3 apresenta de forma sucinta um material de apoio em imunologia e discute alguns conceitos necessários à compreensão deste trabalho. São apresentados os principais modelos usados em Sistemas Imunológicos Artificiais: Redes Imunológicas, Algoritmo de Seleção Clonal e o Algoritmo de Seleção Negativa, e são mencionados alguns artigos relevantes. Além disso, uma pesquisa bibliográfica é apresentada com uma relação de aplicações. Esta pesquisa procura demonstrar as potencialidades dos Sistemas Imunológicos Artificiais e fornece subsídios para o trabalho desenvolvido.

O Capítulo 4 descreve os modelos propostos para geração do conjunto de detectores segundo a representação proposta.

No capítulo 5 são apresentados os estudos de casos e efetuados comentários sobre os resultados obtidos.

A conclusão deste trabalho é apresentada no Capítulo 6 juntamente com uma relação de possíveis trabalhos futuros.