



**Jorge Luís Machado do Amaral**

**Sistemas Imunológicos Artificiais  
Aplicados à Detecção de Falhas**

**Tese de Doutorado**

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUC-Rio.

Orientador: Prof. Ricardo Tanscheit

Rio de Janeiro  
Março de 2006



**Jorge Luís Machado do Amaral**

**Sistemas Imunológicos Artificiais  
Aplicados à Detecção de Falhas**

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Ricardo Tanscheit**  
**Orientador**

Departamento de Engenharia Elétrica – PUC-Rio

**Prof. Marco Aurélio Cavalcanti Pacheco**  
Departamento de Engenharia Elétrica – PUC-Rio

**Prof. Carlos Roberto Hall Barbosa**  
Progr. de Pós-Graduação em Metrologia para Qualidade e Inovação

**Prof. Antônio Carneiro de Mesquita Filho**  
COPPE-UFRJ

**Prof. Flávio Joaquim de Souza**  
UERJ

**Prof. Pedro Henrique Gouvêa Coelho**  
UERJ

**Prof. José Eugenio Leal**  
Coordenador Setorial do Centro  
Técnico Científico – PUC-Rio

Rio de Janeiro, 16 de março de 2006

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

### **Jorge Luís Machado do Amaral**

Graduou-se em Engenharia Eletrônica pela UFRJ em 1991. Obteve o título de mestre em Engenharia Elétrica – Teleinformática e Automação pela COPPE/UFRJ em 1999. Desenvolveu junto à iniciativa privada como engenheiro e consultor, diversos projetos eletrônicos para automação industrial e comercial. É professor do Departamento de Engenharia Eletrônica e de Telecomunicações da Faculdade de Engenharia da Universidade do Estado do Rio de Janeiro desde 1999. Pesquisa novas tecnologias nas áreas de Inteligência Computacional e Detecção de Falhas em sistemas eletrônicos.

#### Ficha Catalográfica

Amaral, Jorge Luís Machado do

Sistemas imunológicos artificiais aplicados à detecção de falhas / Jorge Luís Machado do Amaral ; orientador: Ricardo Tanscheit. Rio de Janeiro : PUC, Departamento de Engenharia Elétrica, 2006.

121 f. ; 30 cm

Tese (Doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica.

Inclui referências bibliográficas.

1. Engenharia Elétrica – Teses. 2. Sistemas imunológicos artificiais. 3. Detecção de falhas. 4. Computação evolucionária. 5. Inteligência computacional. I. Tanscheit, Ricardo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Para minha família, Glória, Danilo, Gabriel, Nala e Sheik com todo meu amor e  
dedicação.

## Agradecimentos

Ao meu orientador Professor Ricardo Tanscheit pelo estímulo e parceria para a realização deste trabalho.

À UERJ e à PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

À minha família, pelas orações, paciência e carinho.

Aos meus pais, pela educação, atenção e carinho de todas as horas.

Aos meus irmãos pelas importantes contribuições e palavras de apoio.

Aos meus amigos por todo apoio e compreensão.

Aos professores que participaram da Comissão examinadora.

A todos os amigos que de uma forma ou de outra me estimularam ou me ajudaram.

## Resumo

Amaral, Jorge Luís Machado do; Tanscheit, Ricardo (Orientador). **Sistemas Imunológicos Artificiais Aplicados à Detecção de Falhas**. Rio de Janeiro, 2006. 121p. Tese de Doutorado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Este trabalho investiga métodos de detecção de falhas baseados em sistemas imunológicos artificiais, especificamente aqueles baseados no algoritmo de seleção negativa (NSA) e em outras técnicas de reconhecimento próprio/não-próprio. Inicialmente, foi proposto um esquema de representação baseado em hiperesferas com centros e raios variáveis e três modelos capazes de gerar detectores, com esta representação, de forma eficiente. O primeiro modelo utiliza algoritmos genéticos onde cada gene do cromossomo contém um índice para um ponto de uma distribuição quasi-aleatória que servirá como centro do detector e uma função decodificadora responsável por determinar os raios apropriados. A aptidão do cromossomo é dada por uma estimativa do volume coberto através 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. Experimentos com dados sintéticos e reais demonstram a capacidade dos algoritmos propostos e que eles apresentam melhorias nos aspectos de escalabilidade e desempenho na detecção de falhas.

## Palavras-chave

Sistemas Imunológicos Artificiais; Detecção de Falhas; Computação Evolucionária; Inteligência Computacional.

## Abstract

Amaral, Jorge Luís Machado do; Tanscheit, Ricardo (Advisor). Artificial Immune Systems **Artificial Immune Systems Applied to Fault Detection**. Rio de Janeiro, 2006. 121p. PhD Thesis - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

This work investigates fault detection methods based on Artificial Immune Systems, specifically the negative selection algorithm (NSA) and other self/non-self recognition techniques. First, there was proposed a representation scheme based on hyperspheres with variable center and radius, and three models, which are very capable to generate detectors, based on that representation scheme, in an effective way. The first model employs Genetic Algorithms where each chromosome gene represents an index to a point in a quasi-random distribution, that will serve as a detector center, a decoder function will be responsible to determine the appropriate radius. The chromosome fitness is given by a valuation of the covered volume, which is calculated through a Monte Carlo integral. The second model uses the Quadtree space partition technique to generate the detectors positions and their radius. The space partition could be done by using a detection function or by recursive divisions of an initial detector that occupies the whole space. In third model, inspired on immune networks, the B cells represent the detectors and the network that is established by them gives the location and radius of each detector. Experiments with syntetic and real data show that the proposed algorithms improve scalability and perform better in fault detection.

## Keywords

Artificial Immune Systems; Fault Detection; Evolutionary Computation; Computational Intelligence.

# Sumário

1	Introdução	13
1.1.	Motivação	13
1.2.	Objetivos	16
1.3.	Contribuições da Tese	16
1.4.	Descrição do Trabalho	17
1.5.	Estrutura da Tese	20
2	Técnicas Inteligentes aplicadas à Detecção e Diagnóstico de Falhas	22
2.1.	O Processo de Diagnóstico	22
2.2.	Técnicas Tradicionais de Diagnóstico de Falhas	24
2.2.1.	Sistemas baseados em Regras	24
2.2.2.	Árvores de Decisão de Falhas	25
2.3.	Abordagens baseadas em modelos (Model Based Reasoning)	26
2.4.	Case Based Reasoning (CBR)	27
2.5.	Abordagens utilizando Lógica Fuzzy	29
2.5.1.	Geração de modelos	29
2.5.2.	Análise de resíduos	30
2.6.	Abordagens utilizando Redes Neurais	33
2.6.1.	Classificação de padrões	34
2.6.2.	Identificação de parâmetros	36
3	Sistemas Imunológicos Artificiais	38
3.1.	Introdução	38
3.2.	Visão Geral do Sistema Imunológico	39
3.2.1.	Reconhecimento dos Agentes Patogênicos	40
3.2.2.	Geração da Diversidade dos Receptores	41
3.2.3.	Maturação da Afinidade	42
3.2.4.	Memória Imunológica	44
3.2.5.	Tolerância ao <i>Próprio</i>	45
3.3.	Metáforas do Sistema Imunológico	47
3.3.1.	O Mecanismo de Seleção Negativa	47
3.3.2.	A Teoria da Rede Imunológica	48
3.3.3.	Princípio da Seleção Clonal	49
3.4.	Sistemas Imunológicos Artificiais	49
3.4.1.	Algoritmo de Seleção Negativa	49
3.4.2.	Redes Imunológicas Artificiais	55
3.4.3.	Algoritmo de Seleção Clonal	57
3.5.	Aplicações	58
4	Modelos Propostos para Geração de Detectores	63
4.1.	RNSA com aprendizado LVQ	63
4.2.	Geração de Detectores de Raios Variáveis por meio de Algoritmos Genéticos	65

4.2.1. Representação Utilizada	67
4.2.2. Função de Aptidão	69
4.3. Geração de Detectores com Raios Variáveis por meio do Particionamento Quadtree	70
4.3.1. Particionamento Quadtree por meio da Função de Detecção	71
4.3.2. Particionamento Quadtree do Detector	73
4.4. Geração de Detectores com Raios Variáveis por meio de Redes Imunológicas	75
4.4.1. Métodos de Otimização SQP	78
4.4.2. Estratégia Evolucionária	79
5 Estudos de Casos	82
5.1. Divisor Resistivo	83
5.1.1. Geração de Detectores por particionamento Quadtree	85
5.1.2. Geração de Detectores por Algoritmos Genéticos	88
5.1.3. Geração de Detectores por meio de Redes Imunológicas	90
5.1.4. Classificadores no caso de falhas não previstas	92
5.2. As Duas Espirais	93
5.2.1. Geração dos Detectores por particionamento Quadtree	93
5.2.2. Geração dos Detectores por Algoritmos Genéticos	95
5.2.3. Geração dos Detectores por Redes Imunológicas	97
5.3. Detecção de Falhas em um Filtro Passa-Banda Sallen Key	98
5.4. Detecção de Falhas em um Filtro Universal	101
5.5. Detecção de Falhas em um Motor de Indução	103
5.6. Detecção de Falhas em Rolamentos	106
6 Conclusões e Trabalhos Futuros	108
6.1. Conclusões	108
6.2. Trabalhos Futuros	110
7 Referências Bibliográficas	113

## Lista de figuras

Figura 2.1 – Exemplo de uma árvore de decisão.	25
Figura 2.2 – Ciclo de Funcionamento de um sistema CBR.	28
Figura 2.3 – Algoritmo do simulador Fuzzy.	30
Figura 2.4 – Localização do ponto em relação aos clusters.	31
Figura 3.1 – Camadas de defesa do sistema imunológico (Castro & Von Zuben, 1999)	39
Figura 3.2 – União entre receptores e epítomos (Castro, 2001)	40
Figura 3.3 – Receptores construídos a partir de bibliotecas (Castro, 2001)	42
Figura 3.4 – Processo de maturação de afinidade (Bradley, 2000b)	44
Figura 3.5 – Tempos de resposta às infecções (Castro, 2001)	45
Figura 3.6 – Maturação das células T (Bradley, 2000b)	46
Figura 3.7 – Processo de co-estimulação (Bradley, 2000b)	47
Figura 3.8 – Redes de Células B (Suzuki & Yamamoto, 2000)	48
Figura 3.9 – Proposta Original do Algoritmo de Seleção Negativa	50
Figura 3.10 – Exemplo de Regra de Detecção	51
Figura 3.11 – Algoritmo RNSA	54
Figura 3.12 – Treinamento do classificador com amostras próprias e não-próprias (Gonzalez et al, 2002)	54
Figura 4.1 Gráfico Área Coberta x Número de Detectores	64
Figura 4.2 – Algoritmo RNSA-LVQ	65
Figura 4.3 Funcionamento de um Algoritmo Genético	67
Figura 4.4 - Exemplo da codificação utilizada	68
Figura 4.5 Determinação dos raios dos quatro primeiros detectores (+)	69
Figura 4.6 – A função Peaks	70
Figura 4.7 – A decomposição Quadtree da função PEAKS	71
Figura 4.8 Conjunto de pontos próprios	72
Figura 4.9 – Função de Detecção	73
Figura 4.10 – Conjunto de detectores usados	73
Figura 4.11 – Fluxograma para particionamento do detector	74
Figura 4.12 – Modelo para descrição de Redes Imunológicas (Perelson, 1989)	76
Figura 4.13 – Exemplo para o cálculo da afinidade	78
Figura 4.14 – Três tipos de mutação auto-adaptativa (Back et al, 1997).	81
Figura 5.1 – O circuito do divisor resistivo do Experimento 1.	83
Figura 5.2 – Distribuição final para o Quadtree.	86
Figura 5.3 Distribuição final dos detectores gerados por GA.	89
Figura 5.4 – Distribuição final dos detectores gerados por IM	91
Figura 5.5 – Um classificador KNN no caso de falhas não previstas	92
Figura 5.6 – As Duas Espirais.	93
Figura 5.7 – Distribuição Final para o Quadtree.	94
Figura 5.8 – Distribuição Final dos detectores (GA)	96
Figura 5.9 – Distribuição Final dos detectores (IM)	97
Figura 5.10 – Circuito do filtro Sallen Key.	99
Figura 5.11 – Circuito do filtro universal.	101
Figura 5.12 – Diferentes ciclos do sinal de corrente pré-processado.	104

## Lista de tabelas

Tabela 5.1 – Raio e Número de Detectores estimados no RNSA original	84
Tabela 5.2 – Cobertura do espaço não-próprio e Número de Detectores (QD)	85
Tabela 5.3 – Resultados dos classificadores obtidos (QD - raio máximo)	86
Tabela 5.4 – Resultados dos classificadores obtidos (QD - raio médio)	87
Tabela 5.5 – Resultados dos classificadores obtidos (QD - raio mínimo)	88
Tabela 5.6 – Cobertura do espaço não-próprio e Número final de Detectores	89
Tabela 5.7 – Resultados dos classificadores obtidos pelo GA	90
Tabela 5.8 – Cobertura do espaço não-próprio e Número de Detectores (IM)	91
Tabela 5.9 – Resultados dos classificadores obtidos (IM)	91
Tabela 5.10 – Cobertura do espaço não-próprio e Número de Detectores (QD)	93
Tabela 5.11 – Resultados dos classificadores obtidos pelo Quadtree	94
Tabela 5.12– Cobertura do espaço não-próprio e Número de Detectores (GA)	96
Tabela 5.13 – Resultados dos classificadores (GA)	96
Tabela 5.14– Cobertura do espaço não-próprio e Número de Detectores (IM)	97
Tabela 5.15 – Resultados dos classificadores (IM)	98
Tabela 5.16– Cobertura do espaço não-próprio e Número de Detectores (GA)	100
Tabela 5.17 – Resultados dos classificadores (GA)	100
Tabela 5.18– Cobertura do espaço não-próprio e Número de Detectores	102
Tabela 5.19 – Resultados dos classificadores	102
Tabela 5.20 – Cobertura do espaço não-próprio e Número de Detectores (QD)	104
Tabela 5.21 – Porcentagem de pontos considerados normais para os sinais apresentados	105
Tabela 5.22 – Resultados dos Testes	105
Tabela 5.23– Cobertura do espaço não-próprio e Número de Detectores (GA)	107
Tabela 5.24 – Resultados dos Testes	107

## Lista de Abreviaturas e Siglas

- AINE** - Rede Imunológica Artificial (*Artificial Immune Network*)
- aiNET** - Rede Imunológica Artificial para Análise de Dados (*Artificial Immune Network for Data Analysis*)
- ARB** - Esfera de Reconhecimento Artificial (*Artificial Recognition Ball*)
- ATMS** - Sistema de Manutenção com Hipótese Baseada em Verdade (*Assumption Based Truth Maintenance System*)
- CLONALG** - Algoritmo de Seleção Clonal (*Clonal Selection Algorithm*)
- CBR** - Inferência baseada em Casos (*Case Based Reasoning*)
- GDE** - Máquina de Diagnóstico Geral (*General Diagnostic Engine*)
- KNN** - K vizinhos mais próximos (*K Nearest Neighbors*)
- LVQ** - Quantização de Vetores por Aprendizagem (*Learning Vector Quantization*)
- MLP** - Perceptron com múltiplas camadas (*Multi-Layer Perceptron*)
- NAT** - Limiar de Afinidade da Rede (*Network Affinity Threshold*)
- NSA** - Algoritmo de Seleção Negativa (*Negative Selection Algorithm*)
- NSDR** - Seleção Negativa com Regras de Detecção (*Negative Selection with Detection Rules*)
- PIG** - Dispositivo de Inspeção de Tubos (*Pipeline Inspection Gizmo*)
- PNN** - Redes neurais probabilísticas (*Probabilistic Neural Networks*)
- RNSA** - Algoritmo de Seleção Negativa com Representação Real (*Real Valued Negative Selection Algorithm*)
- RBF** - Funções de Base Radial (*Radial Basis Functions*)
- RLAIS** - Sistema Imunológico Artificial com Recursos Limitados (*Resource Limited Artificial Immune System*)
- RRNS** - Algoritmo Aleatório de Seleção Negativa com Representação Real (*Randomized Real Valued Negative Selection Algorithm*)
- SSAIS** - Sistema Imunológico Artificial Auto-estabilizável (*Self-Stabilizing Artificial Immune System*)
- SQP** - Programação Quadrática Sequencial (*Sequential Quadratic Programming*)
- XDE** - Máquina de Diagnóstico Geral Estendida (*Extended General Diagnostic Engine*)