

DETECÇÃO DE FALHAS EM SISTEMAS DINÂMICOS: ABORDAGENS IMUNOINSPIRADAS

Tese de Doutorado submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Elétrica.

por

Carlos A. Laurentys de Almeida

Engenheiro de Controle e Automação – UFMG

Mestre em Engenharia Elétrica – UFMG

Prof. Walmir Matos Caminhas

Orientador

Prof. Reinaldo Martinez Palhares

Co-orientador

Fevereiro 2010

Dados Internacionais de Catalogação na Publicação (CIP)

Biblioteca

de Almeida, Carlos A. Laurentys

Detecção de Falhas em Sistemas Dinâmicos: Abordagens Imunoinspiradas / Carlos A.

Laurentys de Almeida.

Belo Horizonte, 2010.

111f.

Tese de Doutorado – Curso de Engenharia Elétrica. Área de Engenharia de Computação e Telecomunicações – Universidade Federal de Minas Gerais, 2010. Orientador: Prof. Walmir Matos Caminhas. Co-orientador: Prof. Reinaldo Martinez Palhares.

REFERÊNCIA BIBLIOGRÁFICA

DE ALMEIDA, Carlos A. Laurentys. **Detecção de Falhas em Sistemas Dinâmicos: Abordagens Imunoinspiradas**. 2010. 111f. Tese de Doutorado – Universidade Federal de Minas Gerais – Belo Horizonte.

CESSÃO DE DIREITOS

NOME DO AUTOR: Carlos A. Laurentys de Almeida

TÍTULO DO TRABALHO: Detecção de Falhas em Sistemas Dinâmicos: Abordagens Imunoinspiradas.

TIPO DO TRABALHO/ANO: Tese / 2010

É concedida a Universidade Federal de Minas Gerais permissão para reproduzir cópias desta tese e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos.

DETECÇÃO DE FALHAS EM SISTEMAS DINÂMICOS: ABORDAGENS IMUNOINSPIRADAS

Carlos A. Laurentys de Almeida

Composição da Banca Examinadora:

Prof. Benjamim Rodrigues Menezes	EE	-	UFMG
Prof. Eduardo Mazoni Andrade M. Mendes	EE	-	UFMG
Prof. Leandro Nunes de Castro Silva	FCI	-	Mackenzie
Prof. Takashi Yoneyama	DEE	-	ITA
Prof. Tomaz Aroldo da Mota Santos	ICB	-	UFMG
Prof. Reinaldo Martinez Palhares	EE	-	UFMG
Prof. Walmir Matos Caminhas	EE	-	UFMG

Dedico esta tese à minha família e meus amigos por todo carinho, apoio e compreensão durante minha *jornada*.

Agradecimentos

Agradeço aos meus amigos e familiares
pela incessante batalha na *construção de conhecimento*.

Entre estes devo citar a presença de meus pais,
que, mesmo nos momentos críticos, me acalentavam.

Destaco o papel vital do corpo docente da UFMG
na sedimentação de conhecimento durante minha vida acadêmica,
mencionando o papel de meu orientador Prof. Walmir Caminhas,
meu co-orientador Prof. Reinaldo Palhares
e o Prof. Benjamim Menezes, além dos muitos outros professores da UFMG
que mostram que lecionar não é apenas transmitir conhecimento,
mas contribuir para a formação de um caráter.

Seguirei com as minhas lembranças e seus ensinamentos, pois a maior
lição não é aquela do quadro de giz,
e sim a postura que assumem perante a dele.

A essas pessoas dedico minha profunda estima e gratidão
por terem sido, verdadeiramente,
meus mestres.

Aos colegas de estudo, entre eles o Thiago Guzella e André Paim, deixo meu
agradecimento pelo seu apoio.

Finalizando, agradeço a Deus pela oportunidade oferecida.

"Não se pode criar alguma coisa valiosa sem determinação. Nos primórdios da força nuclear, por exemplo, conseguir aprovação para construir o primeiro submarino nuclear - O Nautilus - foi quase tão difícil quanto desenhá-lo e construí-lo. As boas idéias não são adotadas automaticamente. Precisam ser impelidas para a prática com paciência e coragem."

— ALMIRANTE HYMAN RICKOVER

Resumo

Esta tese propôs, aplicou e discutiu abordagens imunoinspiradas para detecção de falhas em sistemas dinâmicos. A detecção de falhas se torna cada vez mais desafiadora devido ao aumento de complexidade dos processos e agilidade necessária para evitar o funcionamento incorreto ou até mesmo acidentes. O grande desafio reside na diferenciação entre condições de funcionamento normal e potencialmente de falha. Soluções promissoras para este problema têm emergido por meio de abordagens imunoinspiradas. Esta tese contribuiu com três abordagens para este fim: DF-NKC (Detecção de Falhas inspirada na célula *natural killer*), a DF-DM (Detecção de Falhas inspirada no Modelo do Perigo) e a DF-Multioperacional (Detecção de Falhas inspirada nos algoritmos de seleção negativa). Enquanto a primeira baseou-se nos mecanismos de ativação e reconhecimento das células *natural killer*, a segunda inspirou-se no modelo do perigo associado a um modelo matemático do sistema imune e, finalmente, a terceira focou-se na melhoria dos algoritmos de seleção negativa. As abordagens DF-NKC e DF-DM foram aplicadas no *benchmark* de sistema de atuação de uma válvula provido pela DAMADICS (*Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems*) enquanto que a abordagem DF-Multioperacional foi aplicada no *benchmark* de sistema de acionamento de um motor de corrente contínua. Os resultados evidenciaram que as abordagens propostas são promissoras para a detecção de falhas.

Abstract

This thesis has proposed, implemented and discussed immune-inspired approaches for dynamic systems fault detection. The fault detection is becoming increasingly challenging due to processes complexity and the agility need to prevent malfunction or even accidents. The challenge lies in differentiating between normal operation and potential fault. Promising solutions to this problem has emerged through immune-inspired approaches. This thesis has contributed through three approaches: DF-NKC (fault detection inspired on natural killer cell's mechanisms), DF-DM (fault detection inspired on danger model) and DF-Multioperacional (fault detection based on improvements of negative selection algorithms). Firstly, DF-NKC approach has used concepts inspired on natural killer cells biological mechanisms of activation and maturation. Secondly, DF-DM approach has used danger model inspiration and a mathematical model of immune system. Finally, the DF-Multioperacional approach was based on existing negative selection algorithms. The DF-NKC and DF-DM were applied in a valve actuator system benchmark provided by DAMADICS (Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems) while DF-Multioperacional was applied to fault detection in a direct current motor system benchmark. The algorithms results show that the approaches are promising for fault detection.

Sumário

LISTA DE FIGURAS	xvii
LISTA DE TABELAS	xxiii
LISTA DE ABREVIATURAS E SIGLAS	xxv
LISTA DE ARTIGOS PUBLICADOS, ACEITOS E SUBMETIDOS NO DOUTORADO	xxvii
1 INTRODUÇÃO: CONTEXTO E RELEVÂNCIA DA DETECÇÃO DE FALHAS	1
1.1 Motivação e Relevância	1
1.2 Visão Geral da Tese	5
1.3 Objetivos e Contribuições	5
1.4 Organização do Texto	7
2 REVISÃO BIBLIOGRÁFICA: DETECÇÃO DE FALHAS E SISTEMAS IMUNES ARTIFICIAIS	9
2.1 Detecção de Falhas e sua Tarefa Fundamental	9
2.2 Detecção de Falhas - Processos Associados e Terminologias	11
2.2.1 Processos Associados a Detecção de Falhas	11
2.2.2 Terminologias da Detecção de Falhas	11
2.2.3 Modelagem e Caracterização Temporal de Falhas	12
2.3 Detecção de Falhas - <i>Benchmarks</i> utilizados na Tese	13
2.3.1 Introdução ao <i>Benchmark</i> DAMADICS	13
2.3.2 Introdução ao <i>Benchmark</i> do Motor Elétrico	18
2.4 Detecção Inteligente de Falhas e Sistemas Imunes Artificiais	21
2.4.1 Contexto dos SIAs	22

2.4.2	SIAs Aplicados a Detecção de Falhas	23
2.5	Formulação da Detecção de Falhas desta Tese	25
3	DETECÇÃO DE FALHAS INSPIRADA NOS MECANISMOS DAS CÉ- LULAS <i>Natural Killer</i>	27
3.1	Inspirações Imunes	27
3.1.1	Visão Geral das Células <i>Natural Killer</i>	28
3.1.2	Fase 1: Formação dos Receptores nas Células NK	30
3.1.3	Fase 2: Educação das Células NK	30
3.1.4	Fase 3: Reconhecimento pelas Células NK	31
3.2	Entendendo as Inspirações para a Nova Abordagem	34
3.3	Metodologia	36
3.3.1	Formação dos Receptores das Células NK Artificiais	36
3.3.2	Educação das Células NK Artificiais	38
3.3.3	Reconhecimento pelas Células NK Artificiais	41
3.4	Aplicação do Algoritmo DF-NKC no <i>Benchmark</i> DAMADICS	42
3.4.1	Geração das Massas de Dados	42
3.4.2	Definição do Modelo de Redundância Analítica	45
3.4.3	Definição dos Experimentos	48
3.4.4	Execução dos Experimentos	49
3.4.5	Execução da Simulações	54
3.4.6	Discussão e Análise de Resultados	55
4	DETECÇÃO DE FALHAS INSPIRADA NO MODELO DO PERIGO	61
4.1	Inspirações Imunes	61
4.2	Entendendo as Inspirações para a Nova Abordagem	64
4.3	Metodologia	66
4.3.1	Definição dos Sinais	66
4.3.2	Transdução de Sinais	68
4.3.3	Resposta Imune Final	72
4.4	Aplicação do Algoritmo DF-DM no <i>Benchmark</i> DAMADICS	73
4.4.1	Definição dos Experimentos	74
4.4.2	Execução dos Experimentos	75
4.4.3	Discussão e Análise de Resultados	76

5	DETECÇÃO DE FALHAS INSPIRADA EM APRIMORAMENTOS NO ALGORITMO DE SELEÇÃO NEGATIVA	79
5.1	Visão Geral dos Algoritmos de Seleção Negativa	79
5.1.1	Complexidade Computacional	80
5.1.2	Cobertura do espaço	81
5.1.3	Codificação	81
5.2	Algoritmos de Seleção Negativa Preexistentes	82
5.2.1	Algoritmo de Detectores de Raio Constante	82
5.2.2	Algoritmo V-Detector	83
5.3	Inspiração Imune e Motivação para Aprimoramentos	84
5.4	Metodologia	85
5.4.1	Ferramentas Operacionais	85
5.4.2	Funcionamento	87
5.5	Aplicação do Algoritmo DF-Multioperacional no <i>Benchmark</i> de Coroa Circular	88
5.5.1	Definição da Base de Dados	88
5.5.2	Definição dos Experimentos	88
5.5.3	Execução dos Experimentos	91
5.5.4	Discussão e Análise de Resultados	91
5.6	Aplicação do Algoritmo DF-Multioperacional no <i>Benchmark</i> de Sistemas de Acionamentos do Motor de Corrente Contínua	92
5.6.1	Discussão e Análise de Resultados	92
6	CONCLUSÕES E PERSPECTIVAS FUTURAS	95
6.1	Visão Geral	95
6.2	Proposição: Algoritmo DF-NKC	96
6.2.1	Resumo da Abordagem	96
6.2.2	Conclusões	97
6.2.3	Proposta de Continuidade	97
6.3	Proposição: Algoritmo <i>Danger Model</i>	98
6.3.1	Resumo da Abordagem	98
6.3.2	Conclusões	99

6.3.3	Proposta de Continuidade	99
6.4	Proposição: Algoritmo DF-Multioperacional	100
6.4.1	Resumo da Abordagem	100
6.4.2	Conclusões	100
6.4.3	Proposta de Continuidade	100
	REFERÊNCIAS BIBLIOGRÁFICAS	112

Lista de Figuras

FIGURA 1.1 – Gráfico evidencia o número percentual de acidentes no Brasil em 2007 (último ano disponibilizado pelo MPS) em função da divisão Classificação Nacional de Atividades Econômicas (CNAE) agrupada pelo autor.	3
FIGURA 1.2 – Gráfico de tendência mostrando dados disponíveis na base histórica do Ministério da Previdência Social (MPS) (2009) evidenciando o número de acidentes totais e acidentes relacionados ao processo de fabricação segundo CNAE agrupada.	3
FIGURA 2.1 – Identificação dos tipos de redundância física e analítica	12
FIGURA 2.2 – Esquemático do processo que engloba o atuador utilizado na geração da massa de dados do <i>benchmark</i> DAMADICS. Fonte:(Bartys et al., 2006)	14
FIGURA 2.3 – Entradas e saídas do modelo utilizado como <i>benchmark</i>	15
FIGURA 2.4 – Ilustração evidenciando a diferente evolução das falhas incipientes e falhas abruptas no tempo dependendo de seus parâmetros. Fonte:Bartys et al. (2006)	17
FIGURA 2.5 – Definição da zona de <i>benchmark</i> e dos parâmetros utilizados nos testes (Bartys et al., 2006).	17
FIGURA 2.6 – Representação do sistema de acionamento de corrente contínua para falhas em atuadores. Fonte: (Caminhas, 1997).	19
FIGURA 2.7 – Hierarquias das divisões dos métodos de IC com foco na Computação Natural. Destaque do autor para contextualizar as contribuições desta tese. Fonte: (Dasgupta, 2006; de Castro, 2006).	22

- FIGURA 3.1 – Uma célula NK (ao centro - em roxo) atacando uma célula alvo (canto superior direito - em verde). Grânulos citotóxicos são mostrados como esferas azuis nas bordas das células NK quando ela se encontra com a célula alvo. Fonte: (Kightley, 2009). 28
- FIGURA 3.2 – Receptores das células NK. São evidenciados os receptores compartilhados pelo homem e camundongos das células NK e seus receptores específicos classificados por tipo: receptores das células normais, *stress* e receptores de agentes infecciosos. Fonte: (F. Colucci and Leibson, 2002). 29
- FIGURA 3.3 – Modelo sequencial de formação dos receptores de ativação e inibição. A célula “A” atingiu o equilíbrio nas amplitudes dos sinais de ativação e inibição (basicamente influenciada pelo número de receptores e afinidades) e, portanto, é sensível a alterações na célula alvo. A célula “B” carece de ligantes de inibição tornando-se células pouco responsivas. A célula “C” tem tanto receptores de ativação e de inibição, mas não atingiu o equilíbrio entre eles. Fonte: (Raulet et al., 2001) 31
- FIGURA 3.4 – Estratégias de reconhecimento das células NK. Representação esquemática da interação das células NK com as células alvo (células de tumor, células infectadas por vírus ou bactérias são detectadas por células NK utilizando as estratégias mencionadas.) Fonte: (Vivier, 2006) 32
- FIGURA 3.5 – Equilíbrios da interação células NK e células alvos. Ativação das células NK frequentemente são geradas por diminuição de receptores inibitórios - polígonos (b) ou aumento da expressão de receptores de ativação - círculos (c). (d) Citocinas liberadas (estrelas) alteram o equilíbrio. Fonte: (Carayannopoulos and Yokoyama, 2004) 33
- FIGURA 3.6 – Principais etapas encontradas na literatura para o ciclo de vida das células NK 34
- FIGURA 3.7 – Comparação entre a célula NK do sistema biológico e a célula NK artificial do algoritmo DF-NKC. 35

FIGURA 3.8 – Comparação do modelo imune encontrado na literatura para as células NK e os passos análogos ao algoritmo DF-NKC proposto nesta tese.	35
FIGURA 3.9 – Inicialização dos receptores artificiais das células NK - Implementa a inicialização estocástica dos receptores das células NK inspirado em hipóteses imunes encontradas na literatura.	36
FIGURA 3.10 – Pseudo-algoritmo detalhando o bloco (1) e o bloco (2) da Figura 3.9.	37
FIGURA 3.11 – Algoritmo de Educação - implementa o processo educativo para maximizar o desempenho da população de células NK.	39
FIGURA 3.12 – Pseudo-algoritmo para do processo de Educação.	40
FIGURA 3.13 – Exemplo ilustrativo da maturidade de células NK gerada. A ativação receptores ”+” se refere a uma possível situação anômala e os receptores inibitórios marcados com ”x”. Os círculos nas linhas (soma zero modelos) indicou a soma zero autotolerantes marcadas com círculos. (b) Uma célula NK é apenas acrescentada à população madura se aumenta o desempenho global da população. Neste exemplo, a população tem 4 células NK maduras.	41
FIGURA 3.14 – Diagrama representando como as células NK maduras interagem para definição do alarme de falhas do SIA proposto para detecção de falhas.	42
FIGURA 3.15 – Abordagem utilizada pela tese com os principais passos envolvidos na aplicação do algoritmo DF-NKC no <i>benchmark</i> DAMADICS. . .	43
FIGURA 3.16 – Massas de dados geradas para a aplicação do algoritmo DF-NKC no <i>benchmark</i> DAMADICS.	44
FIGURA 3.17 – Comparação do modelo com os dados em operação sem falhas do sistema dinâmico em estudo para a etapa de construção do modelo.	46
FIGURA 3.18 – Diagrama simplificado da rede neural utilizada. As variáveis de entrada e saída são detalhadas no item 2.3.1.2.	47
FIGURA 3.19 – Evolução do MSE em função do número de épocas para o sistema em treinamento.	48
FIGURA 3.20 – Análise de efeitos principais para os experimentos executados para o índice de desempenho <i>dr</i>	51

FIGURA 3.21 –Análise de efeitos principais para os experimentos executados para o índice de desempenho fa	52
FIGURA 3.22 –Gráfico de pareto para cada um dos parâmetros e o efeito de seus pesos com grau de confiança igual a 95%	53
FIGURA 3.23 –Gráfico de interações entre os parâmetros e seus efeitos.	53
FIGURA 3.24 –Validação cruzada em k-pastas com $k=10$	54
FIGURA 3.25 –Gráfico de médias para execuções das simulações de falhas abruptas gerados com dados da Tabela 3.4. Para cada tipo de falha são apresentadas as médias de dr e fa	56
FIGURA 3.26 –Pareto de desvios padrões das taxas de detecção dr por tipo de falha abrupta com linha de tendência polinomial de 2 ordem para dr para as falhas abruptas altas. Dados fornecidos pela Tabela 3.4 e 3.5. . . .	57
FIGURA 4.1 – De acordo com o Modelo do Perigo, apenas as células danificadas são capazes de liberar alarmes ou sinais de perigo. Fonte: (Matzinger, 2002).	63
FIGURA 4.2 – Entendendo os paradigmas da resposta imune. Fonte: Matzinger (2002)	65
FIGURA 4.3 – Abordagem Imunoinspirada no Modelo do Perigo: uma visão em três macroetapas	65
FIGURA 4.4 – Mapeamento dos sinais de segurança e perigo para o cenário de detecção de falhas usando o Modelo do Perigo.	67
FIGURA 4.5 – Estratégia de processamento de sinais pelas APCs aplicados ao SIA de detecção de falha proposto.	68
FIGURA 4.6 – Exemplo de transdução dos sinais de segurança por uma APC Artificial: Geração do senso de segurança pelo SIA proposto nesta tese.	70
FIGURA 4.7 – Modelo Imune Artificial: Entradas e Saídas dos modelos.	71
FIGURA 4.8 – Conjuntos nebulosos representando o tumor percebido durante a resposta imune artificial.	71
FIGURA 4.9 – Abordagem utilizada pela Tese com os principais passos envolvidos na aplicação do algoritmo DF-DM no <i>benchmark</i> DAMADICS.	73

FIGURA 5.1 – Fluxograma do algoritmo de seleção negativa. (a) Geração de um conjunto válido de detectores (sensoriamento). (b) Monitoramento. Fonte: (de Castro, 2001).	80
FIGURA 5.2 – Problema dos Buracos: Na forma de círculos são representados os detectores e a região central mais clara representa o espaço próprio. Fonte: Balachandran (2005).	81
FIGURA 5.3 – Fluxograma de funcionamento do algoritmo de Raio Constante . . .	82
FIGURA 5.4 – Fluxograma de funcionamento do algoritmo V-detector.	84
FIGURA 5.5 – As operações básicas com os detectores: o cálculo do raio do detector e o movimento da célula detectora.	86
FIGURA 5.6 – Fluxograma de funcionamento do algoritmo DF-Multioperacional. .	87
FIGURA 5.7 – Exemplo de resultado com (a) 200 detectores e com (b) 500 detectores para r_{self} de 0,08. As células claras definem a região própria e as células escuras são os detectores criados pelo algoritmo de seleção negativa de raio constante.	89
FIGURA 5.8 – Exemplos de resultados com o V-detector com (a) 99% de cobertura estimada e (b) 99,9% de cobertura estimada.	90
FIGURA 5.9 – Exemplos de resultados com o algoritmo DF-Multioperacional com (a) convergência por número máximo de detectores e (b) por limite de tentativas de alocação de detectores.	90
FIGURA 5.10 – Análise de desempenho.(a) Cobertura estimada e (b) Taxas de Detecção (%) para o comparativo dos algoritmos estudados.	91
FIGURA 6.1 – Sugestão de continuidade - criação de nova abordagem para interpretar os resultados da detecção inicial gerada pelo algoritmo DF-NKC para permitir detecção de falhas incipientes e diagnóstico de falha. .	97
FIGURA 6.2 – Sugestão de continuidade para o DF-NKC - criação de nova abordagem para interpretar os resultados da detecção inicial gerada pelo algoritmo DF-NKC para permitir detecção de falhas incipientes e diagnóstico de falha.	98

Lista de Tabelas

TABELA 1.1 – Breve descrição de acidentes industriais encontrados na literatura . . .	4
TABELA 2.1 – Variáveis de entrada	15
TABELA 2.2 – Características das variáveis de saída do sistema em estudo	15
TABELA 2.3 – Tipos possíveis de falhas em estudo.	16
TABELA 2.4 – Cenários de falhas explorados nesta tese por meio do simulador fornecido pelo DAMADICS	18
TABELA 2.5 – Trabalhos de aplicações do algoritmo de seleção negativa em detecção de falhas encontrados na literatura	24
TABELA 3.1 – Lista de parâmetros e níveis utilizados para a definição dos experimentos com o algoritmo DF-NKC	49
TABELA 3.2 – Lista de experimentos executados com os resultados médios e desvio padrão para os índices de desempenho do DAMADICS para 10 execuções para cada tipo de falha. O valor dos níveis de cada um dos parâmetros foi definidos na Tabela 3.1.	50
TABELA 3.3 – Lista de parâmetros e níveis utilizados para a definição das simulações com o algoritmo DF-NKC	54
TABELA 3.4 – Desempenho do algoritmo DF-NKC com média e desvio padrão para 10 execuções usando validação <i>10-pastas</i> para cada um dos cenários de falhas abruptas explorados pelo DAMADICS.	55
TABELA 3.5 – Desempenho do algoritmo DF-NKC com média e desvio padrão para 10 execuções usando validação <i>10-pastas</i> para cada um dos cenários de falhas incipientes explorados pelo DAMADICS.	55
TABELA 3.6 – Desempenho comparativo dos índices para o <i>benchmark</i> DAMADICS com os cenários de falhas abruptos de intensidade alta.	58

TABELA 3.7 – Resultados do teste de Friedman e o teste proposto por Iman and Davenport considerando $\alpha = 0,05$	59
TABELA 3.8 – Resultados da classificação média fornecida pelo teste de Friedman. O pós-teste de Nemenyi (Demsar, 2006) indicou o valor de diferença crítica de $CD_{Nemenyi} = 1,35$ $CD_{Bonferroni-Dunn} = 1,29$ e para $\alpha = 0,05$	59
TABELA 4.1 – Valores dos parâmetros do modelo imune utilizados para simulação da resposta das APCs. Fonte: (De Pillis et al., 2005)	75
TABELA 4.2 – Desempenho do Algoritmo DF-DM para os cenários de falhas explorados no DAMADICS	76
TABELA 4.3 – Desempenho comparativo do algoritmo DF-DM para os cenários de falhas abruptos de intensidade alta encontrados na literatura.	76
TABELA 4.4 – Resultados do teste de Friedman e o teste Iman-Davenport para $\alpha = 0,05$	77
TABELA 5.1 – Resultados do algoritmo DF-Multioperacional para o <i>benchmark</i> do motor elétrico.	92
TABELA 6.1 – Trabalhos encontrados sobre modelagem de Sistemas Imunes que podem ser aplicados como proposta de continuidade ao algoritmo DF-DM	99

Lista de Abreviaturas e Siglas

AEM	<i>Anomalous Event Management</i>
APC	<i>Antigen-Presenting Cells</i>
CN	Computação Natural
CNAE	Código Nacional de Atividades Econômicas
CNAE Agrupada	Agrupamento mais específico efetuado pelo autor:
<i>Setor Primário</i>	CNAE de 1 à 10,
<i>Fabricação</i>	CNAE de 11 à 33,
<i>Construção</i>	CNAE 34 à 41,
<i>Comércio</i>	CNAE 45 à 47,
<i>Transporte</i>	CNAE 49 à 53,
<i>Serviços</i>	CNAE 55 à 84,
<i>Saúde</i>	CNAE 86 à 88,
<i>Outros</i>	CNAE 90 à 97 e 99,
<i>Ignorado</i>	CNAE 98.
DF	Detecção de Falhas
DM	<i>Danger Model</i>
GLP	Gás Liquefeito de Petróleo
IA	Inteligência Artificial

IC	Inteligência Computacional
INS	<i>Infectious-Nonsel</i>
KIR	<i>Killer-cell Immunoglobulin-like Receptor</i>
NKC	<i>Natural Killer Cell</i>
MHC	<i>Major Histocompatibility Complex</i>
MLP	Multi-Layer Perceptron
MPS	Ministério da Previdência Social
MSE	<i>Mean Square Error</i>
SI	Sistema Imune
SIA	Sistemas Imunes Artificiais
SIB	Sistema Imune Biológico
SII	Sistema Imune Inato
SNS	<i>Self-Nonsel</i>

Lista de Artigos Publicados, Aceitos e Submetidos no Doutorado

Durante o período de doutorado foram publicados, aceitos e submetidos os seguintes trabalhos relacionados diretamente à tese:

1. Artigo publicado no Congresso Brasileiro de Redes Neurais - Detecção de Falhas em Sistemas Dinâmicos Utilizando Princípios Imunológicos (2006): o artigo apresenta uma discussão geral sobre Sistemas Imunes Artificiais, tendo como o objetivo a avaliação de dois algoritmos baseados na seleção negativa existentes, e na proposição um novo algoritmo - o DF-Multioperacional e comparação de desempenho no *benchmark* de coroa circular. A nova proposição é ainda aplicada em outro *benchmark* de falhas, baseado no modelo dinâmico de um motor de corrente contínua, e seu desempenho analisado;
2. Artigo aceito no periódico *Expert System With Application - Elsevier* intitulado *Design of an Artificial Immune System Based on Danger Model for Fault Detection* (2009): apresenta a metodologia de detecção de falhas em sistemas dinâmicos inspirada no Modelo do Perigo. A abordagem do artigo baseia-se no DM e modelos matemáticos do sistema imune para proposição de uma nova formulação para o sistema de detecção de falhas. Os resultados mostram que a estratégia desenvolvida é promissora para detecção de falhas em sistemas dinâmicos. DOI:10.1016/j.eswa.2009.12.079;
3. Artigo submetido ao periódico *Expert System With Application - Elsevier* ainda em avaliação pela revista intitulado *A Novel Artificial Immune System applied to Fault Detection: The Natural Killer Cell Approach* (2009): apresenta uma metodologia de detecção de falhas inspirada modelos imune das células NK (*Natural Killer*). O

SIA proposto inspira-se nos mecanismos biológicos encontrados para as células NK, tais como: maquinaria de ativação das células NK e o processo de educação. O *benchmark* DAMADICS foi aplicado para comparar o desempenho do SIA proposto com outros algoritmos de detecção de falhas. Os resultados mostram que a nova abordagem desenvolvida proporciona taxa de detecção semelhante a outros métodos da literatura.

Além dos artigos diretamente relacionados à tese, foram publicados e aceitos os seguintes trabalhos no contexto de detecção de falhas:

1. Artigo publicado no Periódico *IEEE Transactions on Power Delivery* intitulado *Intelligent Thermographic Diagnostic Applied to Surge Arresters: A New Approach* (2009) - apresenta e aplica uma nova metodologia para detecção de falhas em pára-raios baseada em dados de termovisão e redes *neuro-fuzzy*.
(DOI:10.1109/TPWRD.2009.2013375);
2. Artigo publicado no Congresso *Proceedings of SPIE (International Society for Optics and Photonics) in Thermosense XXVII* intitulado *Intelligent Detection and Diagnosis of Lightning Arresters Faults using Digital Thermovision Image Processing Techniques* (2005) - apresenta e aplica uma metodologia para detecção de falhas em pára-raios usando um conjunto de redes *neurais* e processamento digital de imagens termográficas (DOI:10.1117/12.601932);
3. Artigo aceito no Periódico *Applied Soft Computing - Elsevier* intitulado *Design of a Pipeline Leakage Detection using Expert System: A Novel Approach* (2009) - apresenta e aplica uma nova metodologia para detecção de vazamentos em dutos de petróleo baseada em comitês de especialistas e técnicas de inteligência computacional (redes neurais e lógica nebulosa).

Capítulo 1

Introdução: Contexto e Relevância da Detecção de Falhas

“We shall understand accidents when we understand human nature”

Kay (Accidents: Some facts and theories, 1971)

Este capítulo salienta a importância da detecção de falhas e discute suas motivações. Descrevem-se os principais aspectos que levaram à necessidade de automatização da detecção de falhas em processos, sua relevância, objetivos, contexto, contribuições e a formalização da tese.

1.1 Motivação e Relevância

A detecção de falhas é um problema importante na área da engenharia de processos. É um dos componentes vitais para o *Abnormal Event Management* (AEM) (Rajshekhar et al., 2007; Taylor and Sayda, 2005). O AEM lida com detecção, diagnóstico e correção de condições anormais nos processos em tempo real de operação. Para que seja efetivo devem ser observadas as etapas de detecção de anormalidades, identificação da causa fundamental, predição de principais consequências de falhas além do planejamento e execução de ações corretivas com restrições temporais (Luo et al., 2004; Fangping, 2003).

O AEM torna-se cada vez mais desafiador devido aos seguintes fatores: o tamanho e complexidade crescente dos processos; o amplo escopo de suas atividades. No que diz

respeito à complexidade, indústrias sofrem uma pressão para aumento na qualidade dos produtos, aumento de produtividade, redução de rejeitos, redução de custos, redução de acidentes e normas ambientais cada vez mais restritivas. Os processos industriais agregam um conjunto cada vez maior de variáveis monitoradas para atender o crescente padrão de qualidade. Para suportar essa demanda, o controle de processos trouxe avanços nas últimas três décadas: ações de controle como abrir e fechar válvulas que antes eram efetuadas pelos operadores, hoje são executadas de forma automática, com auxílio de computadores de processo.

Em contrapartida, considera-se ainda que o AEM é caracterizado como tarefa manual, fazendo com que o tamanho e complexidade dos processos afetem sua operação. Desta forma, o grande número de variáveis que interagem dinamicamente em um processo atribui uma elevada complexidade aos sistemas industriais atuais que, apesar de automatizados, continuam dependentes do desempenho humano. Estudos na literatura elucidam como o erro humano gera acidentes. Estatísticas internacionais industriais mostram que 70% dos acidentes ainda são causados por erros humanos (Venkatasubramanian et al., 2003). Portanto, a crescente complexidade de processos e os erros humanos podem comprometer o andamento operacional e resultar em acidentes catastróficos, com elevadas perdas econômicas, humanas e ambientais.

Analisando o contexto descrito não é surpreendente que pessoas responsáveis pelo AEM tomem frequentemente decisões incorretas. No Brasil, segundo as últimas estatísticas de acidentes industriais divulgadas pelo Ministério da Previdência Social (MPS) (2009), os processos de fabricação são responsáveis pela maior parte dos acidentes (Figura 1.1). O gráfico da Figura 1.2 mostra os dados da base histórica do MPS evidenciando a tendência de acidentes industriais nos últimos 8 anos (dados disponíveis nesta base).

No decorrer da história são relatados acidentes desastrosos. Entre eles, menciona-se o desastre em Bhopal na Índia, em 1984: um dos piores desastres industriais já registrados na história. Durante o acidente ocorreu o vazamento de material químico da *Union Carbide Corporation* resultando em mortes, problemas de saúde graves na população além de impactos econômicos e ambientais. A Tabela 1.1 resume alguns dos acidentes encontrados e seus dados relacionados à impactos humanos.

Os avanços nas ferramentas de automatização do AEM são necessários para aumento da confiabilidade e redução de número de acidentes. Diante do cenário descrito, o desafio é a automatização do AEM por meio de sistemas computacionais para criar




FIGURA 1.1 – Gráfico evidencia o número percentual de acidentes no Brasil em 2007 (último ano disponibilizado pelo MPS) em função da divisão Classificação Nacional de Atividades Econômicas (CNAE) agrupada pelo autor.




FIGURA 1.2 – Gráfico de tendência mostrando dados disponíveis na base histórica do Ministério da Previdência Social (MPS) (2009) evidenciando o número de acidentes totais e acidentes relacionados ao processo de fabricação segundo CNAE agrupada.

Ano	Local	Evento	#mortos
1974	Flisborough (Reino Unido)	Explosão de uma planta devido à ruptura de tubulação.	28
1984	Cubatão (Brasil)	Rompimento de tubulação de gasolina e consequente ignição.	Cerca de 500
1984	Bhopal (Índia)	Liberação de isocianato de metila por explosão de um tanque de armazenamento.	Cerca de 3800
1988	Mar do Norte (entre as costas da Noruega e Dinamarca)	A plataforma <i>Piper Alpha</i> , da Ocidental Petroleum, explode após um vazamento de gás.	167
1995	Costa da Nigéria	Explosão da plataforma de exploração de petróleo da <i>Mobil</i> .	13
2001	Bacia de Campos (Brasil)	Acidente na plataforma P-7 ocasionou vazamento 120 mil litros de óleo.	-
2004	Baía de Parana- guá/PR (Brasil)	Acredita-se que possam ter vazado entre 3 e 4 milhões de litros de três tipos de combustíveis.	-
2005	Texas (Estados Unidos)	Explosão da refinaria da <i>British Petroleum</i> .	15
2008	Georgia (Estados Unidos)	Explosão em refinaria de açúcar.	13
2009	Carolina do Norte (Estados Unidos)	Explosão devido a vazamento de amônia na fábrica de alimentos <i>ConAgra</i> .	-

TABELA 1.1 – Breve descrição de acidentes industriais encontrados na literatura

ferramentas de auxílio à tomada de decisão. Dada a diversidade dos problemas de detecção de falhas, várias metodologias vem sendo desenvolvidas englobando desde técnicas analíticas até técnicas que se baseiam em Inteligência Computacional (IC) (Zidani et al., 2008; Ligang and Daniel, 2009; de Almeida et al., 2009). A automatização do processo de detecção da falha, foco deste trabalho, é o passo inicial para a automatização do AEM.

1.2 Visão Geral da Tese

Esta tese suporta a automatização de detecção de falhas por meio de Computação Natural (de Castro, 2006), tendo como inspiração a Imunologia. A sinergia entre os temas citados gerou as seguintes abordagens: DF-NKC (Detecção de Falhas *Natural Killer Cell*) - inspirada nas células NK (*Natural Killer*), DF-DM (Detecção de Falhas *Danger Model*) - baseada no Modelo do Perigo - e a DF-Multioperacional - baseada em aprimoramentos do algoritmo de seleção negativa.

No que diz respeito à aplicação dos algoritmos, foi utilizado o *benchmark* de detecção de falhas DAMADICS (*Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems*) (Bartys et al., 2006) para os algoritmos DF-NKC e DF-DM, enquanto o algoritmo DF-Multioperacional foi usado o sistema de acionamentos de um motor de corrente contínua (Caminhas, 1997).

1.3 Objetivos e Contribuições

O objetivo deste trabalho foi permitir a automatização do processo de detecção de falhas para reduzir impactos gerados pelos acidentes industriais e aprimorar o apoio à tomada decisão. A automatização foi proposta por meio de sistemas computacionais capazes de indicar condições de falhas, limitando ou mesmo evitando acidentes e seus impactos. Além disso, uma redução do número de variáveis de processos geridas é esperada no contexto da detecção de falhas, fazendo com que a tomada de decisão seja mais ágil. Os sistemas computacionais foram concebidos baseando-se em metodologias propostas pelo autor que foram inspiradas no sistema imune (SI); as abordagens denominadas de imunoinspiradas.

Os sistemas computacionais foram concebidos, implementados, analisados e con-

frontados com outros sistemas encontrados na literatura. As contribuições no contexto de automatização de detecção de falhas foram:

1. Abordagens de Detecção de Falhas (DF) imunoinspiradas:

- DF-NKC (*Natural Killer Cell*) - abordagem inspirada nos mecanismos das células *Natural Killer* (NK) (Vivier et al., 2008; Lanier, 2008). Consistiu em algoritmos baseados nos mecanismos de maturação e ativação das células NK e sua aplicação, validação e comparação com outros algoritmos encontrados na literatura (Lemos Paim, 2007; Previdi and Parisini, 2006);
- DF-DM (*Danger Model*) - abordagem inspirada no Modelo do Perigo (Matzinger, 2002). Consistiu na proposição de um novo algoritmo para detecção de falhas (de Almeida et al., 2010) e sua aplicação, validação e comparação com outros algoritmos encontrados na literatura (Lemos Paim, 2007; Previdi and Parisini, 2006);
- DF-Multioperacional - abordagem baseada em aprimoramentos de algoritmos de seleção negativa com codificação real. Consistiu na proposição de um novo algoritmo para detecção de falhas (Ronacher et al., 2006) e sua aplicação, validação e comparação com outros algoritmos encontrados na literatura (Ji, 2006; Ji and Dasgupta, 2005; Caminhas and Takahashi, 2001).

2. Aplicação das abordagens propostas nos *benchmarks* de DF:

- DAMADICS (Bartys et al., 2006);
- Simulador de falhas para um sistema de acionamento com motor de corrente contínua proposto por Caminhas (1997) e revisitado por D'Angelo et al. (2010), onde o mesmo foi proposto como *benchmark* de detecção de falhas.

3. Implementação em Matlab 6.5 dos algoritmos de seleção negativa V-Detector e algoritmo de Raios Constantes;

Como resultados das contribuições, foram gerados os seguintes artigos:

1. Artigo publicado no Congresso Brasileiro de Redes Neurais intitulado Detecção de Falhas em Sistemas Dinâmicos Utilizando Princípios Imunológicos (2006): o artigo

apresenta uma discussão geral sobre Sistemas Imunes Artificiais, tendo como o objetivo a avaliação de dois algoritmos baseados na seleção negativa existentes, e na proposição um novo algoritmo - o DF-Multioperacional e comparação de desempenho no *benchmark* de coroa circular. A nova proposição é ainda aplicada em outro *benchmark* de falhas, baseado no modelo dinâmico de um motor de corrente contínua, e seu desempenho analisado;

2. Artigo aceito no periódico *Expert System With Application - Elsevier*” intitulado *Design of an Artificial Immune System Based on Danger Model for Fault Detection* (2009): apresenta a metodologia de detecção de falhas em sistemas dinâmicos inspirada no Modelo do Perigo. A abordagem do artigo baseia-se no DF-DM e modelos matemáticos do sistema imune para proposição de uma nova formulação para o sistema de detecção de falhas. Os resultados mostram que a estratégia desenvolvida é promissora para detecção de falhas em sistemas dinâmicos;
3. Artigo submetido ao periódico *Expert System With Application - Elsevier*” ainda em avaliação pela revista intitulado *A Novel Artificial Immune System applied to Fault Detection: The Natural Killer Cell Approach* (2009): apresenta uma metodologia de detecção de falhas inspirada em modelos imunes das células NK (*Natural Killer*). O SIA proposto inspira-se nos mecanismos biológicos encontrados para as células NK, tais como: maquinaria de ativação das células NK e o processo de educação. O *benchmark* DAMADICS foi aplicado para comparar o desempenho do SIA proposto com outros algoritmos de detecção de falhas. Os resultados mostram que a nova abordagem desenvolvida proporciona taxa de detecção semelhante a outros métodos da literatura.

1.4 Organização do Texto

Este trabalho possui os seguintes capítulos:

Capítulo 1: Contexto e Relevância da Detecção de Falhas

O Capítulo 1 salienta a importância da detecção de falhas e discute suas motivações. Descrevem-se os principais aspectos que levaram à necessidade de automatização da detecção de falhas em processos, sua relevância, objetivos, contexto, contribuições e a formalização da tese.

Capítulo 2: Detecção de Falhas e Sistemas Imunes Artificiais

O Capítulo 2 descreve o problema de detecção de falhas. Foi feita uma revisão sobre os principais temas associados à este trabalho incluindo: Detecção de Falhas e Sistemas Imunes Artificiais. Maior enfoque foi dado à formulação do problema e aos tópicos imprescindíveis ao desenvolvimento das proposições.

Capítulo 3: Método de Detecção de Falhas Inspirada nos Mecanismos das Células *Natural Killer* (NK)

O Capítulo 3 apresenta uma das contribuições metodológicas imunoinspiradas desta tese para automatização de detecção de falhas em sistemas dinâmicos: o algoritmo DF-NKC (Detecção de Falhas inspirada nas células *natural killer*). São descritas suas inspirações imunes, simplificações e fluxogramas. Os resultados de sua execução no *benchmark* DAMADICS são apresentados e discutidos.

Capítulo 4: Método de Detecção de Falhas Inspirada no Modelo do Perigo

O Capítulo 4 apresenta uma nova abordagem imunoinspirada para detecção de falhas em sistemas dinâmicos: o algoritmo DF-DM (Detecção de Falha inspirada no Modelo do Perigo). Descrevem-se as inspirações imunes e as simplificações que caracterizam o novo SIA para detecção de falhas. A abordagem proposta é aplicada no *benchmark* da DAMADICS e os resultados são analisados.

Capítulo 5: Método de Detecção de Falhas Inspirada em Aprimoramentos no Algoritmo de Seleção Negativa com Codificação Real

O Capítulo 5 descreve um aprimoramento para o algoritmo da seleção negativa com codificação real - o algoritmo DF-Multioperacional e sua aplicação no contexto de detecção de falhas. O SIA para detecção de falhas é apresentado juntamente com suas inspirações imunes, motivações para aprimoramentos e metodologia. A abordagem proposta é aplicada no *benchmark* de acionamento de um motor de corrente contínua e os resultados são analisados.

Capítulo 6: Conclusões e perspectivas futuras

O Capítulo 6 consolida os temas apresentados nesta tese e as propostas de continuidade associada.

Capítulo 2

Revisão Bibliográfica: Detecção de Falhas e Sistemas Imunes Artificiais

“The formulation of a problem is far more often essential than its solution, which may be merely a matter of mathematical or experimental skill.”

Albert Einstein

Este capítulo descreve o problema de detecção de falhas. É feita uma revisão sobre os principais temas associados incluindo: Detecção de Falhas e Sistemas Imunes Artificiais. Maior enfoque foi dado à formulação do problema e aos tópicos imprescindíveis ao desenvolvimento das proposições.

2.1 Detecção de Falhas e sua Tarefa Fundamental

A palavra detecção deriva do Latim *detectu*, o que significa revelar, tornar perceptível, descobrir. A palavra falha tem origem do Latim *fallia*, o que significa defeitos. O termo detecção de falhas é utilizado para sinalizar se um processo apresenta ou não um desvio não permitido de uma ou mais variáveis ou propriedades.

Desde que os seres humanos começaram a construir máquinas eles naturalmente se preocuparam com sua condição de operação. Por séculos a única forma de aprender sobre o funcionamento anômalo e sua localização era usar seus sentidos, sensações. Eles buscavam alterações de cor, sons diferenciados, vibrações e odores para identificar proble-

mas almejando maior produtividade e confiabilidade em seus processos (Mendonça et al., 2009; Gayaka et al., 2007).

Com o advento do sistema de medição os valores das variáveis de processos puderam ser obtidas com maior precisão permitindo um monitoramento mais facilitado (Dai et al., 2008). Um exemplo pode ser dado para os processos baseados na técnica de termografia (de Almeida et al., 2009). Atualmente existe um espectro amplo de aplicações industriais (Kurilenko, 2004; Wan and Ma, 2009) e na medicina (Helmy et al., 2008) que utilizam esta técnica. As medições de vibração também avançaram, permitindo detecção e diagnóstico em diversos equipamentos (Silva, 2007).

Outro avanço ocorreu com a monitoração computadorizada associada ao uso de aplicações de tempo real (Lu and Sy, 2009; de Almeida et al., 2005; Feng et al., 1998). Em contrapartida aos avanços na monitoração, alguns empecilhos dificultaram a redução de acidentes industriais. Um fator que deve ser levado em consideração é o crescente aumento da complexidade dos processos, dificultando o eficaz gerenciamento das variáveis envolvidas pelo ser humano. Outros complicadores são o aumento na qualidade dos produtos aumentando as variáveis a serem monitoradas e o atendimento de normas ambientais, demandando maior atuação dos responsáveis pelo AEM (Venkatasubramanian et al., 2003). Diante deste cenário, criaram-se novos desafios para o AEM:

1. A instrumentação poderia falhar ou funcionar de forma incorreta, gerando alarmes falsos ou não indicando problemas que eventualmente poderiam estar ocorrendo no processo;
2. Cenário com complexidade crescente, dificultando o gerenciamento de variáveis e conseqüentemente a atuação do operador;
3. Necessidade de conhecimento especializado do processo para evitar ocorrência de acidentes ou minimizar seus impactos.

Atualmente, a terminologia de plantas inteligentes (White, 2003; Bagajewicz, 2009) é utilizada para descrever processos capazes de executar:

1. Prognosticar falhas;
2. Em casos específicos, aplicação de modelos para comparar a saída real de variáveis da planta com o esperado e analisar suas diferenças;

3. Ferramentas para planejamento de operações futuras da planta com alta confiabilidade (ex. controladores sintonizados para reduzir desgaste de atuadores).

É neste contexto que esta tese contribuiu, criando ferramentas que fornecem indicações sobre a ocorrência de anormalidades e falhas nos processos. Focou-se na automatização do processo inicial do AEM, a detecção de falhas. Foi utilizado como fonte de inspiração o SI e para a formulação de algoritmos os Sistemas Imunes Artificiais (SIAs). Apresenta-se no decorrer deste capítulo a terminologia utilizada nesta tese para proposição de metodologia de automatização utilizado a detecção de falhas imunoinspirada.

2.2 Detecção de Falhas - Processos Associados e Terminologias

2.2.1 Processos Associados a Detecção de Falhas

Além da detecção de falhas existem os procedimentos de identificação, diagnóstico de falha e recuperação do processo. A identificação da falha consiste em identificar as variáveis mais importantes para a execução do diagnóstico (Bagajewicz, 2009). O propósito deste procedimento é o foco do operador nas variáveis pertinentes do processo para que, em caso de disfunções dos elementos presentes nos processos, ele possa eliminar os efeitos da falha de forma eficiente. O diagnóstico de falhas determina qual falha ocorreu. Especificamente, o diagnóstico define o tipo, magnitude, localização e instante de ocorrência da falha. A recuperação do processo ou intervenção é a remoção do efeito da falha ou da falha propriamente dita.

2.2.2 Terminologias da Detecção de Falhas

Segundo Chiang et al. (2002) a detecção de falhas basear em (Figura 2.1):

1. *Redundância Física*: os elementos necessários para efetuar a medição e atuação são replicados no processo. Os principais desafios associados a essa abordagem são o custo e disponibilidade de espaço;

2. *Redundância Analítica*: explora as relações analíticas entre as variáveis observadas no processo. A diferença gerada entre o valor estimado e a variável observada é denominada resíduo ou sinal de sintoma (Ding, 2008). Quando o mesmo situa-se próximo de zero, espera-se que o sistema opere numa condição normal.

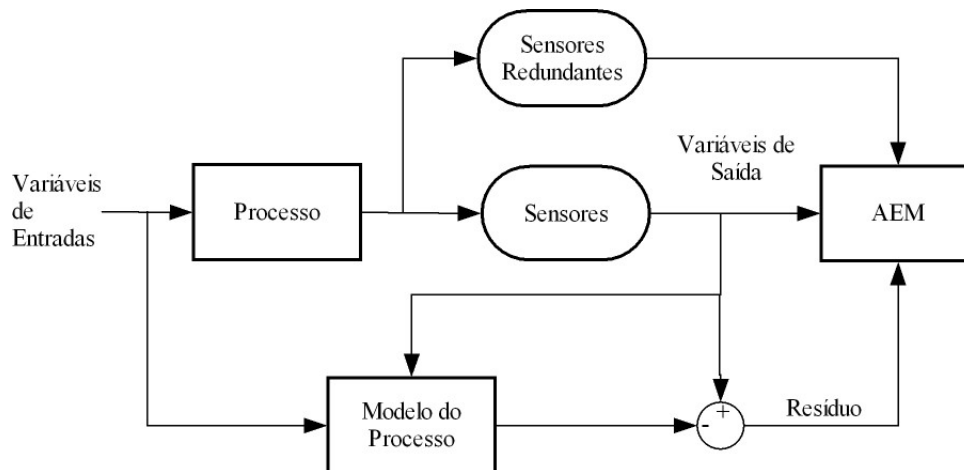


FIGURA 2.1 – Identificação dos tipos de redundância física e analítica

2.2.3 Modelagem e Caracterização Temporal de Falhas

As falhas podem ser classificadas com relação à sua dependência temporal como ((S. Simani and Patton, 2003)):

1. *Abruptas*: são modeladas como uma função degrau e representam um deslocamento ou *off-set* no sinal monitorado. Sua intensidade é modelada pela amplitude da função degrau;
2. *Incipientes*: são falhas que ocorrem gradativamente, se comparadas às falhas abruptas. São modeladas como uma função rampa. A inclinação da rampa é uma medida de velocidade da falha (quanto mais inclinada mais rápida é a falha);
3. *Intermitentes*: são falhas que ocorrem repetidamente no sistema dinâmico. São modeladas como uma combinação de impulsos com diferentes amplitudes em diferentes instantes de tempo.

2.3 Detecção de Falhas - *Benchmarks* utilizados na Tese

2.3.1 Introdução ao *Benchmark* DAMADICS

O *benchmark* foi desenvolvido por um grupo de pesquisa da Europa denominado DAMADICS - *Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems* (Bartys et al., 2006). O DAMADICS simula condições reais de operação de uma fábrica de açúcar polonesa para detecção de falhas. Ele está focado na modelagem de atuadores de válvulas industriais reais e tem características que o tornam uma massa de dados para validação de métodos de detecção e diagnóstico de falhas. Os subitens a seguir detalham o contexto que deu origem ao *benchmark*, as definições dos indicadores de desempenho que permitem a comparação com outros algoritmos, suas entradas, saídas e as falhas para avaliação de desempenho de algoritmos de detecção de falhas.

2.3.1.1 Contexto do *Benchmark*

Os dados do *benchmark* foram gerados por meio de um processo composto de um atuador que controla o fluxo de entrada de água em uma caldeira. Essa caldeira faz parte de um processo de evaporação. O atuador é composto por três elementos distintos: a válvula de controle V, o servo motor pneumático S e o posicionador P (Figura 2.2). A válvula V controla o fluxo de água que passa por um cano que alimenta a caldeira. O servo motor pneumático realiza variações da válvula V, de forma a agir na taxa de fluxo de água. O servo motor é composto por um diafragma preenchido por um fluido, de maneira que, comprimindo o fluido, é possível realizar o deslocamento da haste do motor. A haste do motor está conectada ao plugue da válvula, controlando sua abertura. O posicionador é um dispositivo utilizado para controlar a abertura da válvula em malha fechada por meio da haste do motor, evitando desvios causados por fontes externas ou internas, tais como: atrito, variações na pressão fornecida ao servo motor, etc.

Na Figura 2.2 são mostradas as válvulas V1, V2 e V3 que são acionadas manualmente em caso de contingência. A válvula V3 é uma válvula de *bypass* do acionador. Deste modo, um alarme no atuador pode gerar uma ação de fechamento da válvula V1 e

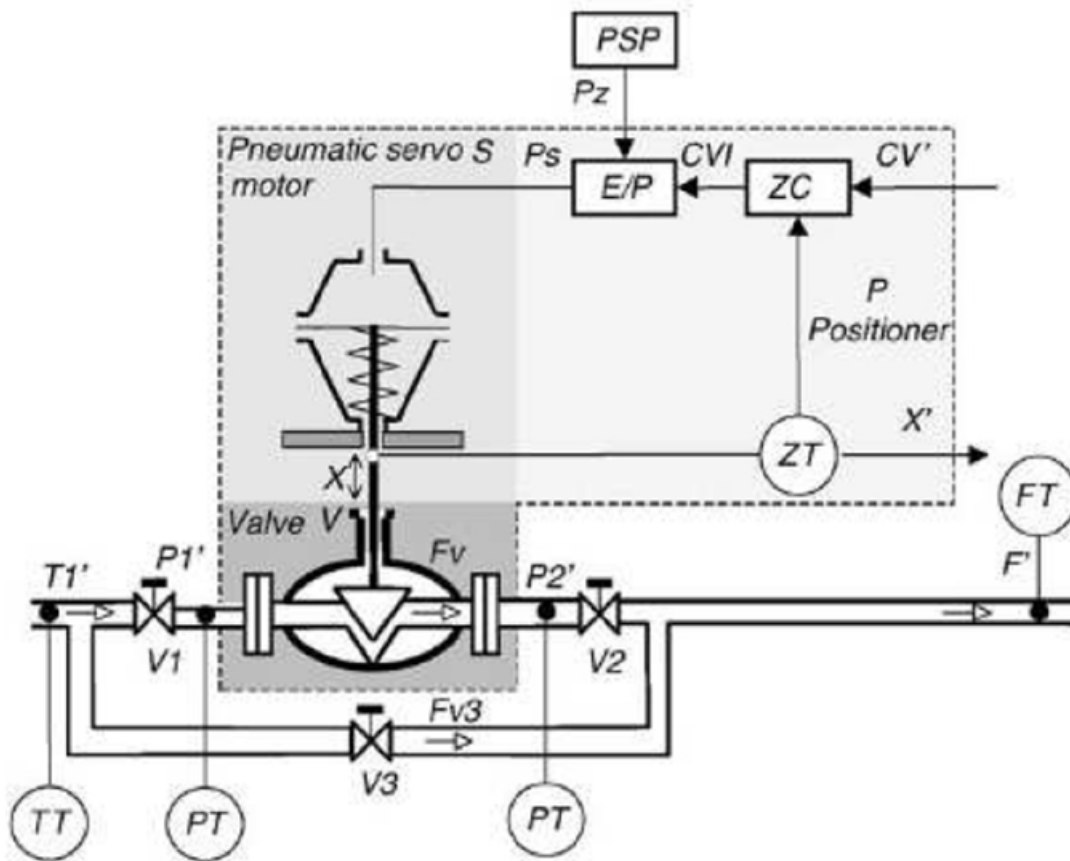


FIGURA 2.2 – Esquemático do processo que engloba o atuador utilizado na geração da massa de dados do *benchmark* DAMADICS. Fonte:(Bartys et al., 2006)

V2 e controle manual do fluxo pela válvula V3.

Utilizou-se o simulador provido pela DAMADICS para criar cenários de falha no atuador em estudo. O simulador faz parte do *benchmark* e foi desenvolvido a partir de descrições analíticas e conhecimentos prévios provindos de um atuador industrial real (Bartys et al., 2006).

2.3.1.2 Entradas e Saídas do *benchmark*

As variáveis de entrada (Tabela 2.1) utilizadas para a detecção de falhas são:

As variáveis de saída (Tabela 2.2) são:

A Figura 2.3 ilustra o modelo de entradas e saídas do simulador.

Todas as variáveis descritas foram amostradas na frequência de 1 Hz (configuração fornecida pelo próprio simulador) e, com exceção de f (vetor de falhas), foram acrescentadas de ruído (provido pelo próprio simulador), simulando erros de medição.

Entrada	Faixa	Unidade	Descrição
CV	[0 1]	-	Sinal de saída do controlador
P1'	-	Pa	Pressão da água na entrada da válvula
P2'	-	Pa	Pressão da água na saída da válvula
T'	-	°C	Temperatura do fluido

TABELA 2.1 – Variáveis de entrada

Saídas	Faixa	Unidade	Descrição
F'	-	ton/h	Fluxo médio medido de água na linha
X'	[0 1]	-	Abertura do plug da válvula

TABELA 2.2 – Características das variáveis de saída do sistema em estudo


2.3.1.3 Falhas geradas pelo *benchmark*

A Tabela 2.3 evidencia os possíveis tipos de falhas que podem ser geradas pelo simulador. Considerando os diversos tipos de falhas, um extenso número de cenários de falhas podem ser gerados. Foram estabelecidos critérios para a geração de cenários de falhas no simulador. Deste modo, cada cenário de falha foi constituído por:

1. intensidade da falha fs ;
2. tempo de desenvolvimento da falha t .

Foram definidos três valores distintos de intensidade de falha: baixa, média e alta que correspondem respectivamente a 25%, 50% e 75% do valor máximo de referência utilizado para simular a falha.

O tempo de desenvolvimento da falha pode ser abrupto ou incipiente. Falhas abruptas ocorrem a partir de um determinado instante temporal, ou seja, dada a intensidade da falha fs e seu instante de início t_{from} . A partir de t_{from} , o vetor de falha f passa de 0 para fs . As falhas incipientes são falhas que são desenvolvidas ao longo do tempo, ou

FIGURA 2.3 – Entradas e saídas do modelo utilizado como *benchmark*

Código	Localização	Descrição
f1	Válvula de Controle	Entupimento
f2	Válvula de Controle	Sedimentação na válvula ou em sua base
f3	Válvula de Controle	Corrosão na válvula ou em sua base
f4	Válvula de Controle	Aumento do atrito na válvula
f5	Válvula de Controle	Vazamento externo
f6	Válvula de Controle	Vazamento interno
f7	Válvula de Controle	Fluxo crítico
f8	Servo motor	Servo motor com haste torcida
f9	Servo motor	Agarramento da haste do servo motor
f10	Servo motor	Perfuração do diafragma do servo motor
f11	Servo motor	Falha na mola do servo motor
f12	Posicionador	Falha no transdutor eletropneumático
f13	Posicionador	Falha no sensor de posicionamento da haste
f14	Posicionador	Falha no sensor de pressão
f15	Posicionador	Falha na mola do posicionador
f16	Geral ou Externa	Queda no suprimento de pressão para o posicionador
f17	Geral ou Externa	Variação inesperada de pressão ao longo da válvula

TABELA 2.3 – Tipos possíveis de falhas em estudo.

seja, a partir de t_{from} , o valor de f aumenta gradativamente até chegar ao valor máximo da intensidade da falha (Figura 2.4).

As falhas incipientes foram divididas em categorias classificadas a partir do tempo necessário para atingir a amplitude máxima, a saber:

- $\Delta t_1 = 15$ minutos;
- $\Delta t_2 = 1$ hora.

A Tabela 2.4 descreve os cenários de falhas que foram utilizados nesta tese.

2.3.1.4 Definições dos indicadores de desempenho

O *benchmark* DAMADICS define os indicadores de desempenho usados para avaliação do algoritmos de detecção de falhas (Bartys et al., 2006). Os indicadores de desempenho do DAMADICS foram calculados na zona de *benchmark*. Essa zona é definida

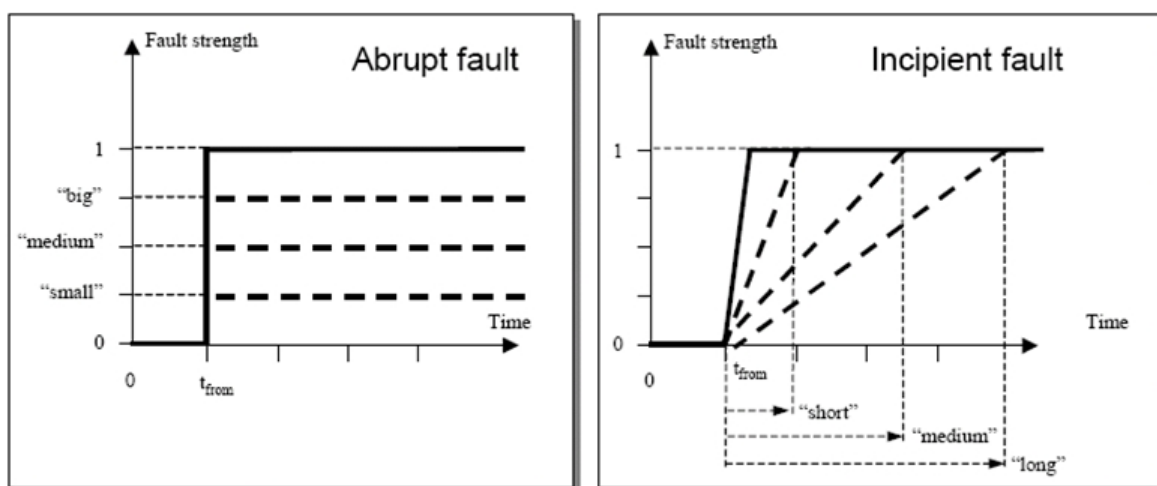


FIGURA 2.4 – Ilustração evidenciando a diferente evolução das falhas incipientes e falhas abruptas no tempo dependendo de seus parâmetros. Fonte: Bartys et al. (2006)

pelos parâmetros evidenciados na Figura 2.5.

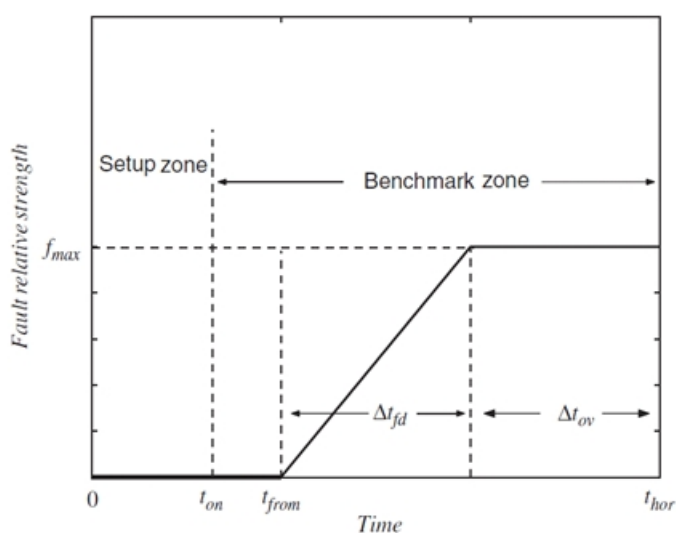


FIGURA 2.5 – Definição da zona de *benchmark* e dos parâmetros utilizados nos testes (Bartys et al., 2006).

Os índices de desempenho do *benchmark* utilizados foram:

- Taxa de Detecção na região de *benchmark* de falha (dr), onde $0 \leq dr \leq 1$. Representa a fração de tempo na zona de *benchmark* com ocorrência de falha ($t_{from} \leq t \leq t_{hor}$) na qual o algoritmo de detecção de falhas detectou a falha corretamente;
- Alarme Falso na região de *benchmark* sem falha (fa), onde $0 \leq fa \leq 1$.

Id	Abr. Alta	Abr. Média	Abr. Baixa	Incipiente
f1	x	x	x	-
f2	-	-	-	Δt_1
f3	-	-	-	Δt_1
f4	-	-	-	Δt_2
f5	-	-	-	Δt_1
f6	-	-	-	Δt_1
f7	x	x	x	-
f8	x	x	x	-
f9	-	-	-	Δt_1
f10	x	x	x	-
f11	-	-	-	Δt_1
f12	x	x	x	-
f14	x	x	x	-
f15	x	-	-	-
f16	x	x	x	-
f17	x	-	-	-

TABELA 2.4 – Cenários de falhas explorados nesta tese por meio do simulador fornecido pelo DAMADICS

Representa a fração de tempo na zona de *benchmark* sem ocorrência de falha ($t_{on} \leq t \leq t_{from}$) na qual o algoritmo indica ocorrência de falha.

Para as falhas abruptas (de intensidades altas, médias e baixas) utilizou-se (Previdi and Parisini, 2006):

- $t_{on} = 500$ segundos;
- $t_{from} = 900$ segundos;
- $t_{hor} = 1800$ segundos.

Para as falhas incipientes utilizou-se:

- $t_{on} = 500$ segundos;
- $t_{from} = 900$ segundos;
- $t_{hor} = 4000$ segundos.

2.3.2 Introdução ao *Benchmark* do Motor Elétrico

O algoritmo DF-Multioperacional foi aplicado para detecção de falhas utilizando dados de um modelo de acionamento de um motor de corrente contínua evidenciado pela

Figura 2.6 (Caminhas, 1997; Caminhas and Takahashi, 2001). No modelo dinâmico do motor elétrico considerou-se que as variáveis medidas foram:

- i_a - Corrente de armadura;
- i_{fd} - Corrente de campo;
- w_r - Velocidade de rotação.




FIGURA 2.6 – Representação do sistema de acionamento de corrente contínua para falhas em atuadores. Fonte: (Caminhas, 1997).

A representação do modelo na forma de equação de estado do modelo do motor de CC é dada por (Caminhas, 1997):

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \end{bmatrix} = \begin{bmatrix} -k_{aa} \cdot \frac{r_a}{L_a} & -k_{aa} \cdot \frac{L_{afd}}{L_a} \cdot x_3 & 0 \\ 0 & -k_{afd} \cdot \frac{r_{fd}}{L_{fd}} & 0 \\ \frac{L_{afd}}{J_m} \cdot x_2 & 0 & -\frac{B_m}{J_m} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} \frac{1}{L_a} & 0 \\ 0 & \frac{1}{L_{fd}} \\ 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} k_{aa} \cdot \bar{k}_{cca} \cdot v_a \\ k_{afd} \cdot \bar{k}_{ccfd} \cdot v_{fd} \end{bmatrix} \\ + \begin{bmatrix} 0 \\ 0 \\ -1 \end{bmatrix} \cdot [TL]$$

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} \bar{k}_{i_a}^f & 0 & 0 \\ 0 & \bar{k}_{i_{fd}}^f & 0 \\ 0 & 0 & \bar{k}_{\omega_r}^f \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}, \quad \text{onde} \quad \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} i_a \\ i_{fd} \\ \omega_r \end{bmatrix} \quad e \quad \bar{k}_i = 1 - k_i$$

onde os parâmetros do motor são:

- r_a : resistência do circuito da armadura;
- r_{fd} : resistência do circuito de campo;
- L_a : indutância do circuito da armadura;
- L_{fd} : indutância do circuito de campo;
- L_{afd} : indutância mútua armadura / campo;
- TL : conjugado mecânico exigido pela carga;
- B_m : coeficiente de atrito viscoso;
- J_m : momento de inércia do sistema motor / carga.

E os coeficientes de falha aplicados a este modelo são:

- $k_{aa} \in \{0, 1\}$, sendo que $\{0\}$ indica a desconexão do conversor da armadura;
- $k_{afd} \in \{0, 1\}$ sendo que $\{0\}$ indica a desconexão do conversor do campo;

- $k_{cca} \in \{0, 1\}$, sendo que $\{1\}$ indica curto-circuito do conversor da armadura;
- $k_{ccfd} \in \{0, 1\}$, sendo que $\{1\}$ indica curto-circuito do conversor do campo;
- $k_{i_a}^f \in \{0, 1\}$, sendo que $\{1\}$ indica falha no sensor da corrente da armadura;
- $k_{i_{fd}}^f \in \{0, 1\}$, sendo que $\{1\}$ indica falha no sensor da corrente do campo;
- $k_{\omega_r}^f \in \{0, 1\}$, sendo que $\{1\}$ indica falha no sensor de velocidade da máquina.

O modelo foi simulado durante 3 segundos de operação, com a falha começando a atuar no tempo $t = 1,5$ segundos. O algoritmo de detecção de falhas a ser avaliado recebe como entrada três variáveis, a saber:

- corrente do circuito de armadura i_a ;
- velocidade de rotação w_r ;
- corrente do circuito de campo i_{fd} .

Mais detalhes desse *benchmark* podem ser encontrados em (Caminhas, 1997).

2.4 Detecção Inteligente de Falhas e Sistemas Imunes Artificiais

O termo detecção inteligente de falhas refere-se a execução do procedimento de detecção de falhas usando métodos de Inteligência Computacional (IC) (Bezdek, 1992; Fulcher and Jain, 2008). Especificamente, quando se trata do uso de metáforas da natureza como meio de inspiração para desenvolvimento de ferramentas computacionais, trazemos o contexto da Computação Natural (de Castro, 2006) (Figura 2.7). Caso as metáforas sejam fornecidas pelo SI, delimitamos os Sistemas Imunes Artificiais (SIAs) (Timmis et al., 2008a; de Castro and Timmis, 2002; Timmis et al., 2008b). Eles pode ser entendidos como uma forma de conectar a engenharia (especificamente neste trabalho, a Detecção de Falhas) à Imunologia. Foram descritos a seguir o contexto e uma breve revisão bibliográfica dos SIAs encontrados na literatura.

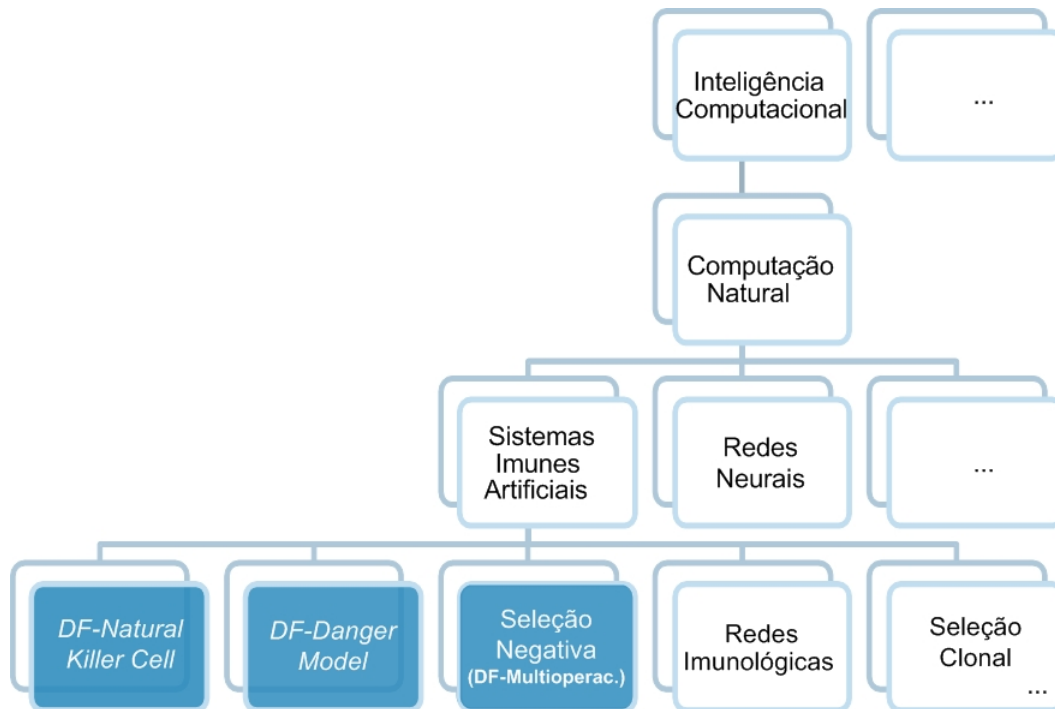


FIGURA 2.7 – Hierarquias das divisões dos métodos de IC com foco na Computação Natural. Destaque do autor para contextualizar as contribuições desta tese. Fonte: (Dasgupta, 2006; de Castro, 2006).

2.4.1 Contexto dos SIAs

O estudo de SIAs é um campo de pesquisa que tenta explorar os mecanismos do Sistema Imune Biológico (SIB) desenvolvendo técnicas para prover soluções de problemas de engenharia (de Castro and Timmis, 2002). Os SIAs são desenvolvidos por meio de técnicas como modelagem computacional da imunologia, matemática, abstração de modelos em algoritmos além de projeto e implementação no contexto da engenharia. Nas áreas de engenharia e computação, tem surgido um forte interesse pelo estudo do SI devido, principalmente, à sua capacidade de processamento de informação. Sob uma perspectiva de engenharia, existem diversas características deste sistema que podem ser destacadas (de Castro, 2001):

- *Unicidade*: cada indivíduo possui seu próprio SIB, com suas capacidades e vulnerabilidade particulares;
- *Reconhecimento de padrões*: as células e moléculas são reconhecidas podendo ativar ou não o SI;
- *Detecção de anomalia*: o SI pode detectar e reagir em função das condições a que ele é exposto;

- *Detecção imperfeita (tolerância a ruídos)*: reconhecimento perfeito não é necessário para que o SIB reaja contra uma situação adversa;
- *Diversidade*: existe uma quantidade limitada de células e moléculas no SI que são utilizadas para se obter o reconhecimento de um número muito grande de elementos, incluindo aqueles sintetizados em laboratório;
- *Memória (detecção baseada em assinatura)*: os componentes do SI bem sucedidos no reconhecimento permitindo uma resposta futura mais intensa e efetiva;
- *Distribuído*: SIB é composto de milhões de agentes ou componentes distribuídos no corpo.

Os SIAs têm suas inspirações na seleção clonal (de Castro and Von Zuben, 2002), seleção negativa (Gonzalez and Dasgupta, 2004), nas redes idiotípicas (Neal, 2003) e nas células dendríticas (Greensmith et al., 2005) com diversos outros desenvolvimentos baseados nestes quatro tipos de algoritmos. Neste contexto, os SIAs conectam a imunologia à engenharia por meio de metáforas para a criação de novos paradigmas de sistemas computacionais.

2.4.2 SIAs Aplicados a Detecção de Falhas

Diversos estudos foram feitos sobre SIA e detecção de falhas gerando modelos imunoinspirados (Calisto et al., 2008; Uyar et al., 2009; Gan et al., 2009). Durante pesquisa bibliográfica, foram encontrados algoritmos baseados na seleção negativa aplicados ao problema de detecção de falhas. A Tabela 2.5 evidencia alguns trabalhos encontrados e suas aplicações.

Além de algoritmos de seleção negativa, trabalhos envolvendo as redes imunes (Ishida and Mizessyn, 1992) e seleção clonal (L. Fang and Rongsheng, 2004) aplicadas à detecção de falhas também foram encontrados. Entre eles, Kim and Bentley (2002), que investigaram o uso dos mecanismos de seleção clonal para a detecção de intrusos. O algoritmo DERA (Dynamic Effector Regulatory Algorithm) proposto por Guzella et al. (2007) para detecção de falhas inspirou-se na interação entre células T.

Autor	Metodologia	Aplicação
Dasgupta and Forrest (1995)	<i>Negative Selection Algorithm</i>	Detecção de Falhas em Ferramentas associadas ao processo de moagem.
González (2003)	NSDR – <i>Negative selection with detection rules</i> e NSFR <i>Negative selection with fuzzy detection rules</i> .	Detecção de Intrusos em Redes de Computadores e detecção de Câncer de Mama.
D. Dasgupta and Berry (2004)	MIDL (<i>Multi-level Immune Learning Detection</i>)	Detecção de falhas de uma aeronave <i>Boeing C-17</i> .
Balachandran (2005)	<i>Multi-Shaped Detector Generation</i> .	Detecção de Quebra em ferramentas e dados biomédicos.
Ji (2006)	<i>V-Detector</i>	Diagnóstico Dental.
Amaral (2006)	<i>Algoritmos de Seleção Negativa baseado em hiperesferas com centros e raios variáveis</i>	Detecção de Falhas.
Zeng et al. (2007)	<i>Feedback Negative Selection Algorithm</i>	Detecção de anomalias.
Zhaoxiang et al. (2008)	<i>Matrix Negative Selection Algorithm</i>	Detecção de anomalias.
Ren and Wang (2008)	<i>Seleção negativa inspirada em algoritmos genéticos e Simulating Annealing</i>	Detecção de anomalias em sistemas de bombeamento.
Jian et al. (2009)	<i>Non-dimensional parameter immune detectors</i>	Detecção de anomalias.

TABELA 2.5 – Trabalhos de aplicações do algoritmo de seleção negativa em detecção de falhas encontrados na literatura

2.5 Formulação da Detecção de Falhas desta Tese

No decorrer desta tese a DF foi formulada como um problema de classificação de padrões. A DF foi tratada como um problema dicotômico, com classe de operação normal e classe de operação com falha. A detecção de falhas indicou então a qual classe pertencia a condição do sistema: normal ou falha. Especificamente, no que diz respeito aos algoritmos DF-NKC e DF-DM, a tese focou-se na detecção inteligente de falhas em sistemas dinâmicos por meio de redundância analítica com o *benchmark* DAMADICS (seção 2.3.1) objetivando a detecção de falhas *abruptas* e *incipientes*. A inspiração do algoritmo DF-NKC foi nos mecanismos de ativação e maturação das células NK. A inspiração do algoritmo DF-DM foi no modelo do perigo e no modelo matemático imune descrito por De Pillis et al. (2005). O algoritmo DF-Multioperacional inspirou-se em aprimoramentos dos algoritmos de seleção negativa existentes e foi aplicado ao *benchmark* do sistema de acionamento de um motor de corrente contínua (seção 2.3.2) e focou-se na detecção de falhas por meio do mapeamento da região não própria.

Capítulo 3

Detecção de Falhas Inspirada nos Mecanismos das Células *Natural Killer*

“Grandes descobertas e progressos invariavelmente
envolvem a cooperação de várias mentes.”

Alexander Graham Bell.

Este capítulo apresenta uma das contribuições metodológicas imunoinspiradas desta tese para automatização de detecção de falhas em sistemas dinâmicos: o algoritmo DF-NKC (Detecção de Falhas inspirada nas células *natural killer*). São descritas suas inspirações imunes, simplificações e fluxogramas. Os resultados da sua execução no *benchmark* DAMADICS são apresentados e discutidos.

3.1 Inspirações Imunes

O algoritmo DF-NKC inspirou-se nos modelos imunes encontrados na literatura que descrevem os comportamentos das células *Natural Killer* - NK. Essa seção consolida os principais comportamentos das células NK encontrados que inspiraram o novo SIA para detecção de falhas.

3.1.1 Visão Geral das Células *Natural Killer*

As células NK têm um papel de destaque no Sistema Imune Inato (SII) pois estão envolvidas em defesas iniciais contra células que podem sofrer diversos tipos de estresses como infecções e tumores (Vivier et al., 2004). As células NK possuem atividade citotóxica e capacidade de liberação de diversas citotoxinas e citocinas (Moretta, 2007) como ilustra a Figura 3.1. Essas características evidenciam que as células NK são capazes de provocar a morte celular e de liberar moléculas de comunicação celular, gerando sinais que influenciam o comportamento de outras células.




FIGURA 3.1 – Uma célula NK (ao centro - em roxo) atacando uma célula alvo (canto superior direito - em verde). Grânulos citotóxicos são mostrados como esferas azuis nas bordas das células NK quando ela se encontra com a célula alvo. Fonte: (Kightley, 2009).

Diversos trabalhos foram publicados objetivando dissecar os mecanismos que permitem as células NK, componentes essenciais do SII, discriminar as células alvos e células com estresse das células saudáveis (Luci et al., 2009). No que diz respeito ao reconhecimento efetuado pelas células NK, trabalhos recentes encontrados na literatura apontam para uma estratégia embasada em receptores de ativação e inibição (Lanier, 2008; Luci and Tomasello, 2008). Atualmente, sabe-se que existem diversos tipos de receptores de ativação (receptores contendo ITAM - *Immunoreceptor Tyrosine-based Activating Motifs*) e inibição (receptores contendo ITIM - *Immunoreceptor Tyrosine-based Inhibitory Motifs* (Johansson and Höglund, 2006; López-Larrea et al., 2008)) em cada célula NK (Figura 3.2). Isso significa que os mecanismos de ativação das células NK são compostos por moléculas de ativação e inibição que são capazes de conectá-las em superfícies moleculares (ligantes) da células alvo. Desta forma, as células NK conseguem detectar alterações de superfície celular - transformação maligna ou infecção - pela perda, ganho

ou alteração de moléculas em suas superfícies. Sua função é, portanto, regulada por um balanço dinâmico entre as interações dos seus receptores com os da célula alvo. Essa interação definirá se a célula alvo sofre ação citotóxica e regula a quantidade de citocinas que a célula NK liberará.




FIGURA 3.2 – Receptores das células NK. São evidenciados os receptores compartilhados pelo homem e camundongos das células NK e seus receptores específicos classificados por tipo: receptores das células normais, *stress* e receptores de agentes infecciosos. Fonte: (F. Colucci and Leibson, 2002).

Segundo Johansson and Höglund (2006), no que diz respeito ao seu mecanismo de ativação celular, a característica de autotolerância deve ser contemplada. Neste caso, a célula NK não deve ser ativada quando em contato com as células saudáveis. Um ponto de destaque para a detecção por meio do balanço dinâmico dos sinais de ativação e inibição é entender como essas moléculas, ou receptores, são gerados para cada célula NK. Na literatura foram encontrados modelos de geração estocástica dos receptores das células NK (Yokoyama et al., 2004). Entretanto, alguns artigos apontam um processo complementar, denominado de processo de educação das células NK. Esse processo aperfeiçoaria o funcionamento dos receptores para cada célula (Raulet et al., 2001; Anfossi et al., 2006) depois do processo de geração estocástica.

Com base nas características encontradas na literatura, células NK têm seu ciclo de vida descrito pelos passos:

- Fase 1 - *Início da expressão dos receptores*: é descrita pela geração de células NK imaturas, onde os receptores de inibição e ativação são gerados por meio de um processo estocástico;

- Fase 2 - *Processo de Educação*: visa aperfeiçoar as propriedades discriminatórias das células NK imaturas. Serão geradas células NK maduras por meio de expressão dos receptores de ativação e inibição;
- Fase 3 - *Reconhecimento*: células NK interagem com outras células do organismo e dependendo do equilíbrio dinâmico entre os sinais inibitórios e de ativação e liberar citocinas.

3.1.2 Fase 1: Formação dos Receptores nas Células NK

O processo de formação dos receptores das células NK gera seus receptores de ativação e inibição. Segundo a literatura, os receptores são gerados por um mecanismo estocástico, que baseia-se nas hipóteses de *At least One* e na de equilíbrio *Zero-sum* (Raulet et al., 2001). A hipótese *At least One* propõe que para a realização de autotolerância (não ativar em condição indevida) as células NK devem ter pelo menos um receptor de inibição, evitando portanto que ela seja ativada indevidamente. A proposição do equilíbrio *Zero-sum* (Figura 3.3) é gerar equilíbrios de desenvolvimento durante a fase de formação dos receptores de ativação e inibição.

Desta forma, os estados de desenvolvimento das células NK são:

- Célula NK Madura - célula que alcançou o equilíbrio entre os receptores de ativação e inibição (ex. célula ‘A’ da Figura 3.3);
- Célula NK Imatura - célula que não será ativada uma vez que para atingir o equilíbrio faltam receptores de inibição (ex. célula ‘B’ da Figura 3.3);
- Célula NK Quase-Madura - célula que ainda não alcançou o equilíbrio entre os receptores de ativação e inibição (ex. célula ‘C’ da Figura 3.3) e através do processo educativo pode atingir o equilíbrio.

3.1.3 Fase 2: Educação das Células NK

Embora um mecanismo estocástico delineie inicialmente as expressões dos receptores das células NK, seu repertório final parece ser moldado e aprimorado por um outro processo: o processo educativo (Johansson et al., 2005; Brodin et al., 2009; Raulet et al., 2001).




FIGURA 3.3 – Modelo sequencial de formação dos receptores de ativação e inibição. A célula “A” atingiu o equilíbrio nas amplitudes dos sinais de ativação e inibição (basicamente influenciada pelo número de receptores e afinidades) e, portanto, é sensível a alterações na célula alvo. A célula “B” carece de ligantes de inibição tornando-se células pouco responsiva. A célula “C” tem tanto receptores de ativação e de inibição, mas não atingiu o equilíbrio entre eles. Fonte: (Raulet et al., 2001)

Segundo Johansson et al. (2005); Raulet et al. (2001) este processo juntamente com o processo de Formação dos Receptores nas Células NK permitirá a geração de um conjunto de células NK úteis, ou com melhores capacidades discriminatórias.

De forma geral, objetivo do processo educativo é aperfeiçoar as propriedades discriminatórias das células NK. Seus efeitos almejam gerar um repertório de células NK autotolerantes (Johansson and Höglund, 2006). No trabalho de Johansson et al. (2009) alguns modelos matemáticos são propostos para tentar explicar o mecanismo de educação sofrido pelas células NK, entretanto este processo ainda é pouco compreendido (Vivier, 2006).

3.1.4 Fase 3: Reconhecimento pelas Células NK

Uma vez gerada a população de células NK maduras, elas passam a interagir com outras células. A ativação das células NK é regulada por um equilíbrio dinâmico entre os sinais positivos (ativação) e negativos (inibitórios) (Figura 3.4).

Desta forma, os estados de uma célula NK madura são:




FIGURA 3.4 – Estratégias de reconhecimento das células NK. Representação esquemática da interação das células NK com as células alvo (células de tumor, células infectadas por vírus ou bactérias são detectadas por células NK utilizando as estratégias mencionadas.)
 Fonte: (Vivier, 2006)

- Ativada por ausência de sinais de inibição (*Missing Self*): os receptores da célula NK interagiram com os da célula alvo e sua ativação foi desencadeada pela falta de ligantes na célula alvo. Um exemplo típico no SIB são as moléculas de MHC (*Major Histocompatibility Complex*) Classe I. Em situação normal, essas substâncias estão presentes nas superfícies de todas as células nucleadas do corpo (exceto hemácias). Durante uma infecção viral ou em células tumorais, sua expressão é reduzida e sua ausência é percebida pelas células NK num processo denominado de ausência do sinal próprio ou *Missing Self*. Este processo é mediado por uma diversidade de ITIM das células NK que geram sinais inibitórios (ex. Ly49D, NKG2C e KIR (*Killer-cell Immunoglobulin-like Receptors*)) (Colonna, 1998);
- Ativada por sinais de ativação (*Stress-Induction* e *Infectious Non-self*): as células NK foram ativadas quando seus receptores interagem com os ligantes de ativação da célula alvo. Um exemplo típico de receptor das células NK para células de tumor são os receptores NKG2D (López-Larrea et al., 2008);
- Inativada: os receptores da célula NK interagiram com célula alvo e as interações

não foram suficientes para desencadear sua ativação.

Situações típicas de equilíbrio dinâmico de uma célula NK são ilustradas pela Figura 3.5.

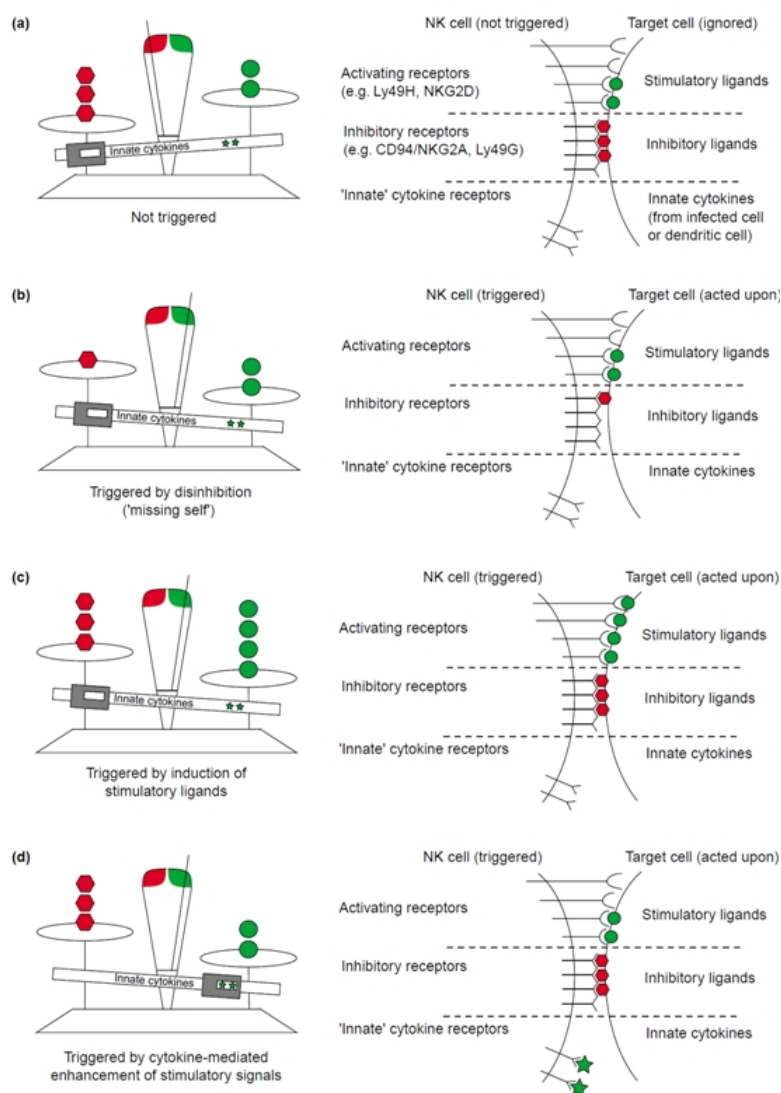


FIGURA 3.5 – Equilíbrios da interação células NK e células alvos. Ativação das células NK frequentemente são geradas por diminuição de receptores inibitórios - polígonos (b) ou aumento da expressão de receptores de ativação - círculos (c). (d) Citocinas liberadas (estrelas) alteram o equilíbrio. Fonte: (Carayannopoulos and Yokoyama, 2004)

Ressalta-se que a presença de citocinas altera os mecanismos de ativação das células (Moretta, 2007). Em geral, as células NK são capazes de liberar diferentes tipos de citocinas, dependendo da interação molecular. O equilíbrio dinâmico de uma célula NK pode ser alterado por citocinas, facilitando seu desencadeamento ou deixando-o mais difícil.

3.2 Entendendo as Inspirações para a Nova Abordagem

A literatura descrita de forma breve na Seção 3.1 contextualiza os mecanismos imunes das células NK (Figura 3.6). Esses mecanismos inspiraram a proposição de um novo SIA para a detecção de falhas: o algoritmo DF-NKC (Detecção de Falhas inspirada nas células *Natural Killer*). As principais fontes de inspiração do DF-NKC foram:

1. Formação dos receptores das células NK: os mesmos são gerados de forma estocástica, aplicando as hipóteses de *At Least One* e *Zero-sum*;
2. Processo de Educação: a resposta imune das células NK é moldada pelo equilíbrio dinâmico dos sinais dos receptores de ativação e inibição. Os receptores das células NK sofrem um processo de aperfeiçoamento por meio de um mecanismo de educação objetivando maximizar o seu desempenho;
3. Fase de Reconhecimento: As células NK resultantes do processo de educação têm contato com células alvo podendo ser ativadas com base no balanço entre seus receptores de inibição e ativação e secretar citocinas.

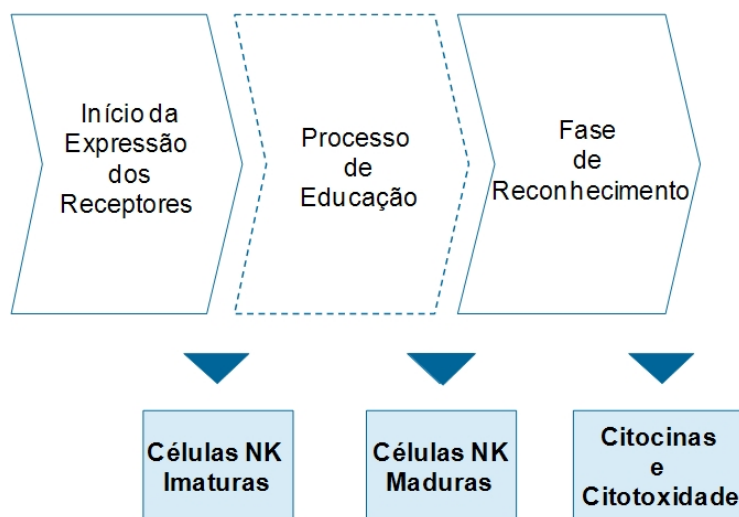


FIGURA 3.6 – Principais etapas encontradas na literatura para o ciclo de vida das células NK

Neste cenário, os dados disponíveis (funcionamento normal e de falha) têm papel análogo aos receptores de inibição e ativação das células NK. Portanto, os dados normais são entendidos como receptores inibidores e os de falha como receptores de ativação.

A Figura 3.7 compara a célula NK do SIB com a célula NK artificial gerada pelo algoritmo DF-NKC. No algoritmo DF-NKC, a célula NK inspira o projeto de uma classe denominada de Célula NK que tem atributos como, por exemplo, os seus receptores de ativação e inibição e métodos para calcular sua liberação de citocinas.

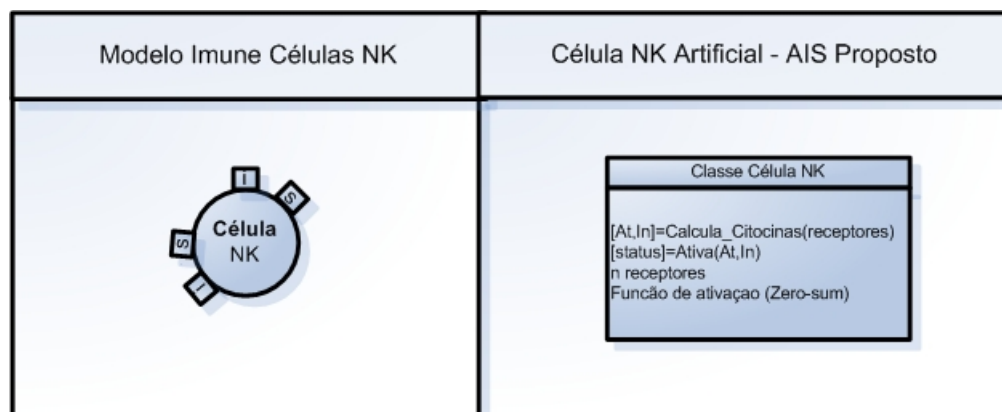


FIGURA 3.7 – Comparação entre a célula NK do sistema biológico e a célula NK artificial do algoritmo DF-NKC.

A Figura 3.8 resume as analogias baseadas em inspirações dos mecanismos das células NK. O detalhamento de cada uma dessas etapas encontra-se na Seção 3.3.

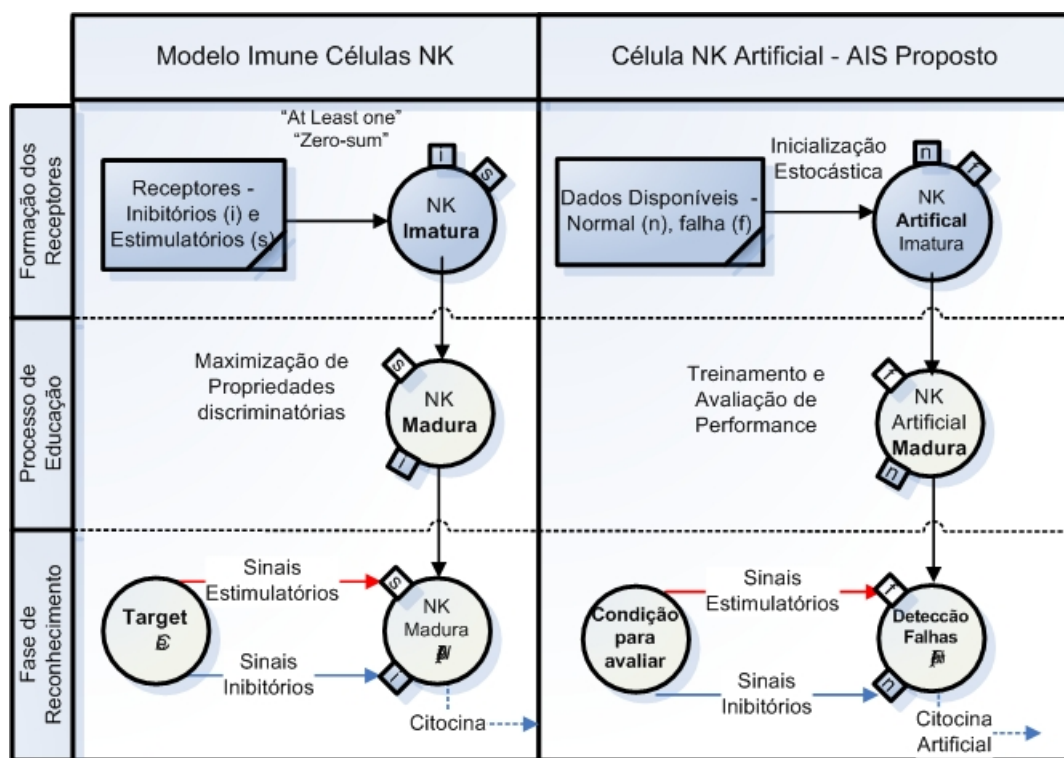


FIGURA 3.8 – Comparação do modelo imune encontrado na literatura para as células NK e os passos análogos ao algoritmo DF-NKC proposto nesta tese.

3.3 Metodologia

A metodologia proposta inspirou-se nas estratégias de reconhecimento das células NK encontradas na literatura. Essas fases, de agora em diante, recebem a palavra artificial ao seu final para indicar que foram implementadas por meio de sistemas computacionais. As seções a seguir detalham cada um destes passos e suas implementações.

3.3.1 Formação dos Receptores das Células NK Artificiais

Esta fase embasou-se em uma metáfora da fase de inicialização estocástica dos receptores de células NK gerando células NK imaturas. A Figura 3.9 descreve as principais etapas do algoritmo de Inicialização dos receptores artificiais das células NK.

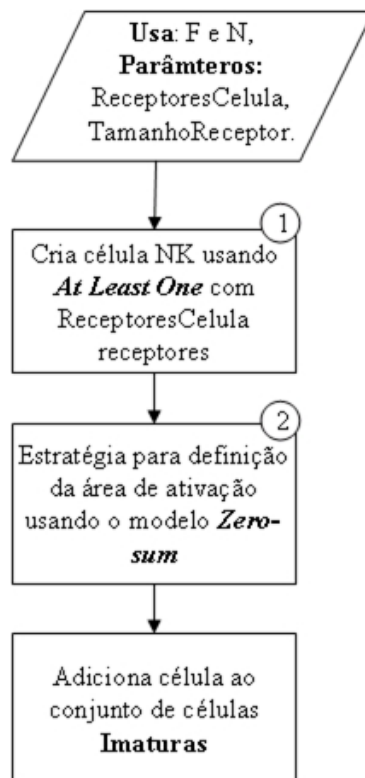


FIGURA 3.9 – Inicialização dos receptores artificiais das células NK - Implementa a inicialização estocástica dos receptores das células NK inspirado em hipóteses imunes encontradas na literatura.

O modelo artificial da hipótese *At least one* encontra-se representado pelo bloco (1) da Figura 3.9. Ele gerou o repertório de receptores de células NK com pelo menos um receptor inibidor a fim de criar células NK responsivas.

O pseudo-algoritmo da implementação do modelo *At least one* e do *zero-sum* é descrito por meio da Figura 3.10.

```

Dados:
N_t: conjunto de receptores de inibição para criação da célula
F_t: conjunto de receptores de ativação para criação da célula
TamanhoReceptores: número de padrões por receptor
ReceptoresCelula: # de receptores
CelulaNK: classe que encapsula os parâmetros das células NK

Function [nkcell] = 1_Cria_CélulaNK_At_Least_One(N_t,F_t,TamanhoReceptores, ReceptoresCelula);

Valida (ReceptoresCelula >= 1); % valida at least one
nkcell = new CelulaNK();
nkcell.ReceptorInib = cria_receptor (N_t, ReceptoresCelula);
nkcell.ReceptorAtiv = cria_receptor (F_t, ReceptoresCelula);
return nkcell;

Function [Imature_nkcell] = 2_Estratégia_Zero_sum (nkcell);

for j=1: size(nkcell.ReceptorInib)
    dist_xi = (nkcell.ReceptorInib - nkcell.ReceptorAtiv)/2;
    activating_vec = cell.xa + dist_xi;
    Imature_nkcell.Zero_Sum = InterpolPontosMedios(activating_vec);
end;
return Imature_nkcell;

```

FIGURA 3.10 – Pseudo-algoritmo detalhando o bloco (1) e o bloco (2) da Figura 3.9.

O modelo artificial da hipótese de equilíbrio *Zero-sum* encontra-se representado pelo bloco (2) da Figura 3.9. Este algoritmo definiu a região de ativação das células NK. Inicialmente, o equilíbrio baseou-se no número de receptores, produzindo um conjunto equilibrado de receptores inibitórios e de ativação. Considerou-se também a afinidade entre os receptores de inibição e ativação para definição da resposta da célula NK. Este modelo foi representado pela equação de uma reta, definida pela interpolação dos pontos médios entre um receptor de inibição e todos os receptores de ativação da célula NK.

O algoritmo de Formação dos Receptores das Células NK Artificiais teve como entradas:

- Conjunto de Receptores de Falha “F” - $[x_1 \dots x_n]$: Estes representam os valores das n variáveis de processo afetadas quando a falha ocorre. Estes componentes geram os receptores de ativação das células NK;
- Conjunto de Receptores Normais “N” - $[y_1 \dots y_n]$: Estes representam os valores das n variáveis de processo em condições normais. Estes componentes geram os receptores de inibição das células NK.

O algoritmo teve como parâmetros:

- ReceptoresCelula - r : Constante real. Representa o número de receptores (inibição e ativação) das células NK;
- TamanhoReceptor - s : Constante real. Representa o comprimento do receptor gerado para cada uma das células NK.

3.3.2 Educação das Células NK Artificiais

O objetivo do mecanismo de educação é maximizar as propriedades discriminatórias da população NK como tolerância e seus mecanismos de reconhecimento. O Mecanismo de Educação gera células NK maduras a partir das células imaturas. O algoritmo artificial de educação proposto avaliou a tolerância como sendo a taxa de falsos positivos e o desempenho individual da população como sendo sua taxa de detecção como critério de desempenho (Figura 3.11).

O pseudo-algoritmo da implementação do modelo de Educação é descrito por meio da Figura 3.12.

Um ponto de destaque do algoritmo de Educação Artificial é representado pelo bloco (1) da Figura 3.11 onde as propriedades discriminatórias (autotolerância e capacidades de reconhecimento) são avaliadas. Em primeiro lugar, o limiar de maturação é verificado: um desempenho mínimo deve ser alcançado, pois caso não seja, a célula será descartada. Em segundo lugar, o algoritmo de Educação Artificial considerou que as células NK são autotolerantes - significando neste contexto que as células não são ativadas indevidamente, reduzindo alarmes falsos. Portanto, um mecanismo de evitar ativação indevida de células NK foi aplicado. Neste caso, o algoritmo remove o modelo *Zero-sum* artificial (linha equações) que ativa em situação inadequada. Se todos os modelos da célula violarem, ela é eliminada da população. Finalmente, o desempenho de cada célula (taxa de detecção) é avaliado como sendo uma medida de sua utilidade para a população. A célula NK avaliada somente é adicionada à população madura se ela melhorar o desempenho da população. Esta restrição tem como objetivo criar uma população que sempre melhora o desempenho com um número limitado de células NK (parâmetro *MaximoCelulas*). A Figura 3.13 ilustra o resultado final da execução deste algoritmo e como o desempenho da população variou com sua execução.

Os parâmetros-chave do algoritmo são:

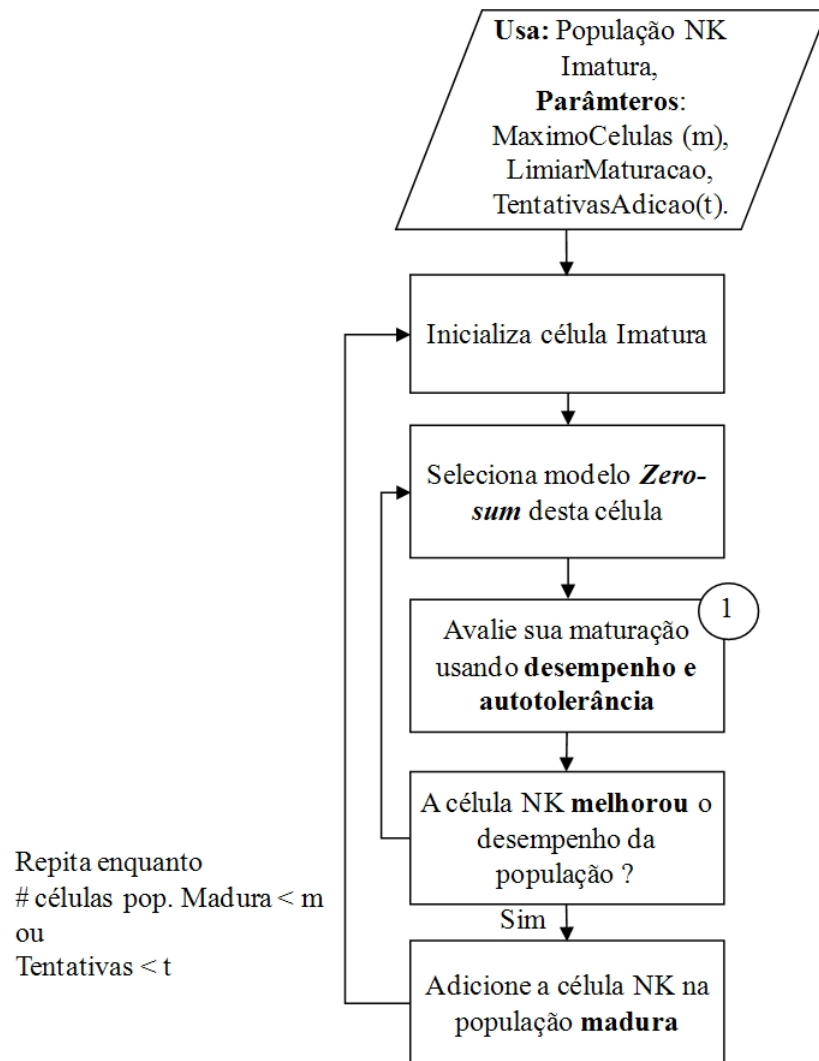


FIGURA 3.11 – Algoritmo de Educação - implementa o processo educativo para maximizar o desempenho da população de células NK.

N_v: conjunto de receptores de inibição para educação da célula
F_v: conjunto de receptores de ativação para educação da célula
Imature_nkcell: objeto da classe *CelulaNK* gerado pela função *2_Estratégia_Zero_sum*
Pop.assess: desempenho da população madura sendo gerada

```
Function [Mature_nkcell] = 1_AvaliaMaturação (Imature_nkcell, N_v, F_v)

for ( i =1:size(Imature_nkcell.Zero_Sum)) % apaga receptores autotolerantes
    for (j=1: size(N_v))
        bTolerante = Tolerante (N_v(j), Imature_nkcell.Zero_Sum(i))
        if (not bTolerante) then
            Apaga(Imature_nkcell.Zero_Sum(i));
        end;
    end;

    for (j=1: size(F_v)) % para cada receptor de ativação
        NotDetected(j) = Tolerante (F_v(j), Imature_nkcell.Zero_Sum(i))
    end;

Imature_nkcell.assess = (1 - NotDetected/size(F_v) )/* 100;

if (Imature_nkcell.assess) <= LimiarMaturação then
    Apaga(Imature_nkcell);

if (Imature_nkcell.assess) <= (Pop.assess) then
    Apaga(Imature_nkcell);

return Imature_nkcell;
```

FIGURA 3.12 – Pseudo-algoritmo para do processo de Educação.

- *MaximoCelulas*: Constante real. Define o número máximo de células NK maduras da população de células NK;
- *LimiarMaturacao*: Constante real. Representa o mínimo desempenho necessário das células NK para que possam aderir a população;
- *TentativasAdicao*: Constante real. Representa o número máximo de tentativas de adicionar as células NK imaturas na população madura. Trata-se de um critério de parada do algoritmo de Educação Artificial.

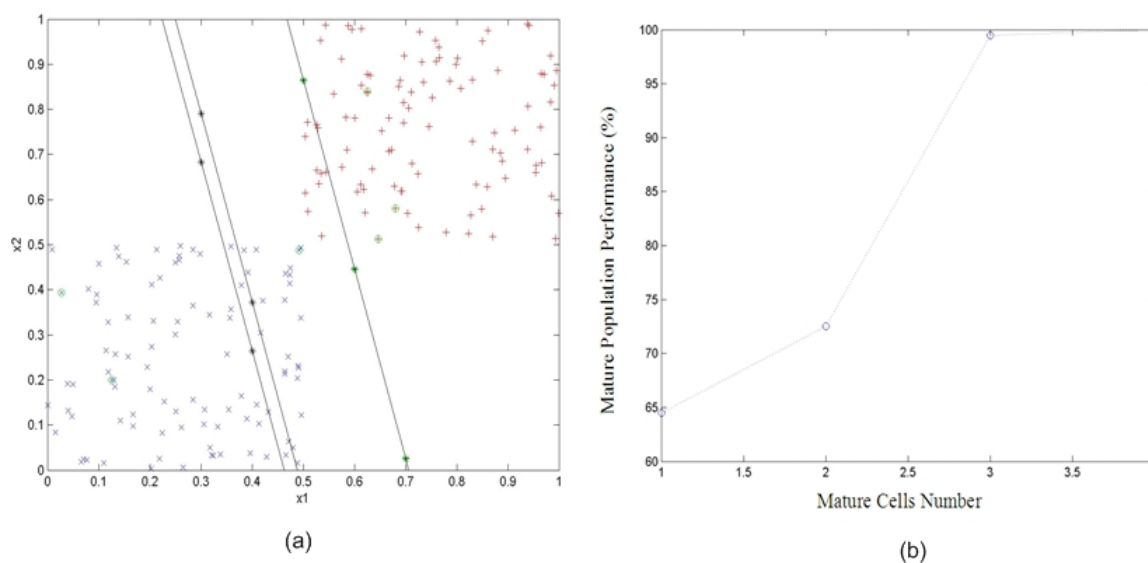


FIGURA 3.13 – Exemplo ilustrativo da maturidade de células NK gerada. A ativação receptores ”+” se refere a uma possível situação anômala e os receptores inibitórios marcados com ”x”. Os círculos nas linhas (soma zero modelos) indicou a soma zero autotolerantes marcadas com círculos. (b) Uma célula NK é apenas acrescentada à população madura se aumenta o desempenho global da população. Neste exemplo, a população tem 4 células NK maduras.

3.3.3 Reconhecimento pelas Células NK Artificiais

A população de células NK maduras interage com os ligantes da célula alvo que deseja classificar em condição falha (ativação) ou normal (inativação), conforme mostra a Figura 3.5. Desta interação são gerados os seguintes parâmetros:

- Citocina - gerada com base na distância euclidiana entre os receptores da célula alvo e sua reta de equilíbrio. Caso o ponto de interação esteja acima do equilíbrio, ocorrerá a liberação de citocinas de ativação (valor positivo) indicando situação de ativação e caso contrário indicando inibição (valor negativo);
- Status (Ativada ou Inativada) - o status será ativado caso as citocinas de ativação (positivas) sejam maiores que as citocinas de inibição (negativas) e inativada caso contrário.

O SIA para detecção de falhas proposto considera a geração de alarme baseando-se no voto majoritário do status (maioria ativada ou não) da população madura (Figura 3.14).

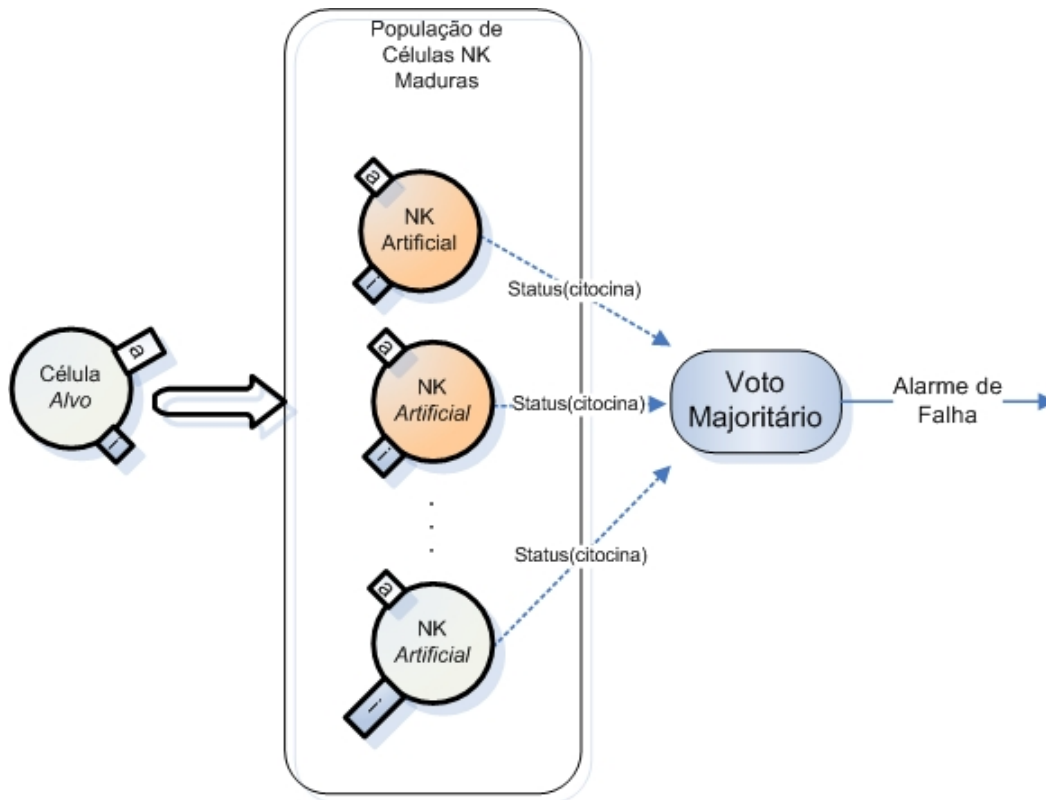


FIGURA 3.14 – Diagrama representando como as células NK maduras interagem para definição do alarme de falhas do SIA proposto para detecção de falhas.

3.4 Aplicação do Algoritmo DF-NKC no *Benchmark*

DAMADICS

Esta seção descreve os passos para aplicação da abordagem DF-NKC no *benchmark* DAMADICS. A Figura 3.15 resume os principais passos detalhados nos itens seguintes.

3.4.1 Geração das Massas de Dados

O processo de geração de massa de dados objetivou a geração de conjuntos apropriados para as etapas de Redundância Analítica, Experimentos e Simulações.

Para o processo de Redundância Analítica foi utilizado somente o conjunto de dados em operação normal do processo, totalizando 5.000 pontos. Optou-se por gerar dois conjuntos disjuntos: um para treinamento (com metade dos pontos) e outro para validação (com os demais pontos).

Para a etapa de Experimentos uma massa de dados foi gerada contendo três subconjuntos disjuntos. O primeiro conjunto diz respeito aos dados para a fase de inicialização

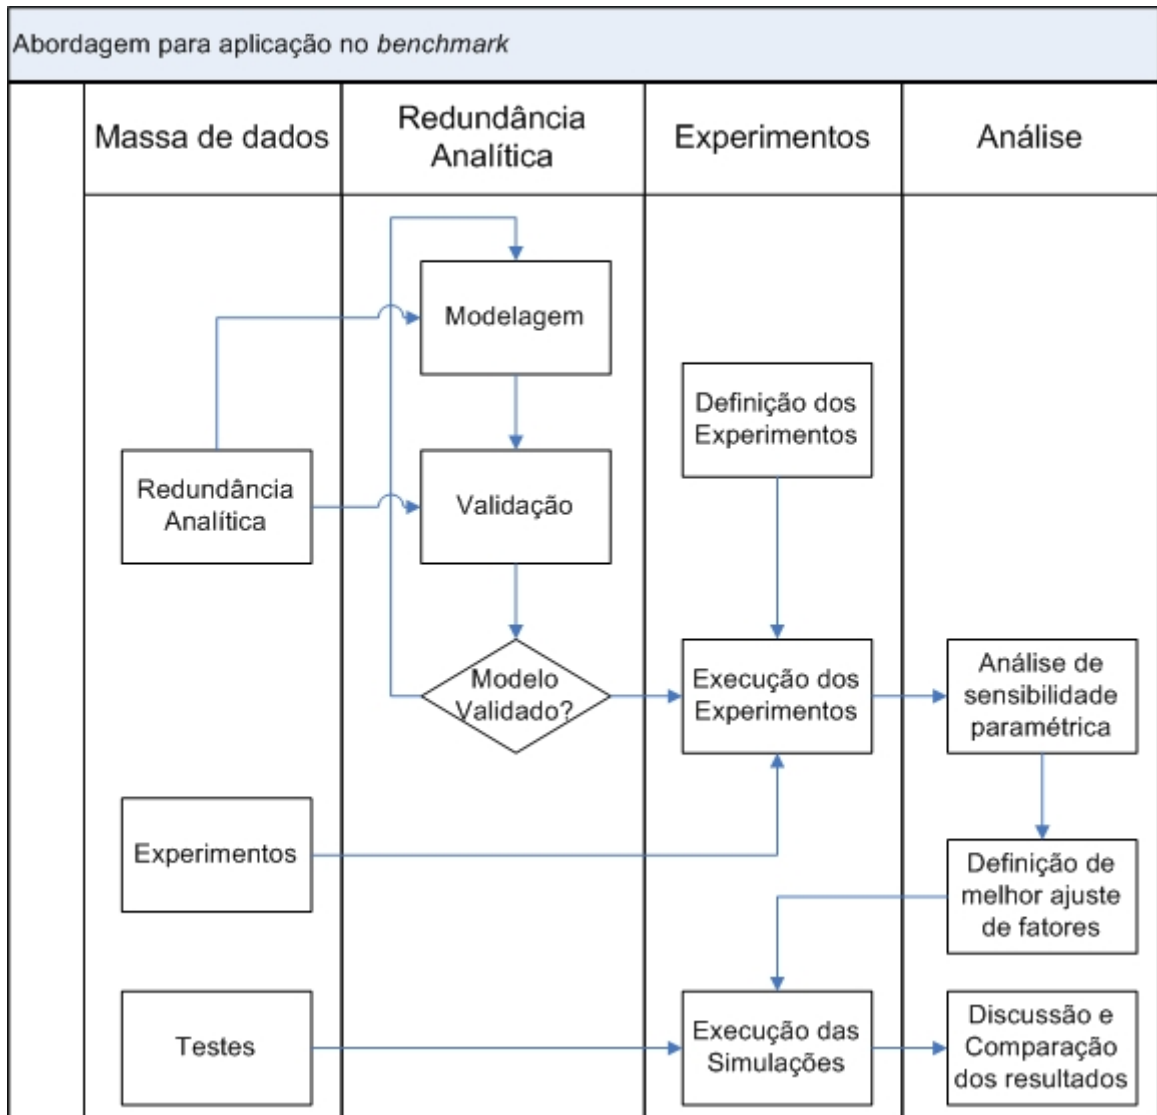


FIGURA 3.15 – Abordagem utilizada pela tese com os principais passos envolvidos na aplicação do algoritmo DF-NKC no *benchmark* DAMADICS.

dos receptores do algoritmo DF-NKC, sendo denominado de conjunto de treinamento. O segundo conjunto foi utilizado para a fase de educação das células NK artificiais, sendo denominado de conjunto de validação. O terceiro conjunto denominado de testes foi utilizado para a fase de monitoração, que gerou os índices de desempenho do algoritmo DF-NKC, conforme proposto pelo *benchmark* DAMADICS. É importante mencionar que as massas de treinamento e validação foram subdivididas para permitir a validação cruzada com 10-pastas. Deste modo, o conjunto de treinamento e validação foi alternado.

Foi utilizada uma estratégia para definição das massas de dados para os experimentos e para as simulações em função dos tipos de falhas em cada uma dessas etapas. Para a etapa de experimentos, apenas as falhas abruptas altas f1, f7, f15, f17 foram utilizadas. Essa definição foi utilizada para gerar um ajuste específico para um conjunto de falhas, uma vez que os mesmos seriam comparados com outros encontrados na literatura (detalhes no item 3.4.3). Já a massa de dados de simulação incluiu as demais falhas abruptas altas, médias e baixas além das falhas incipientes. Um resumo das massas de dados é apresentada na Figura 3.16.

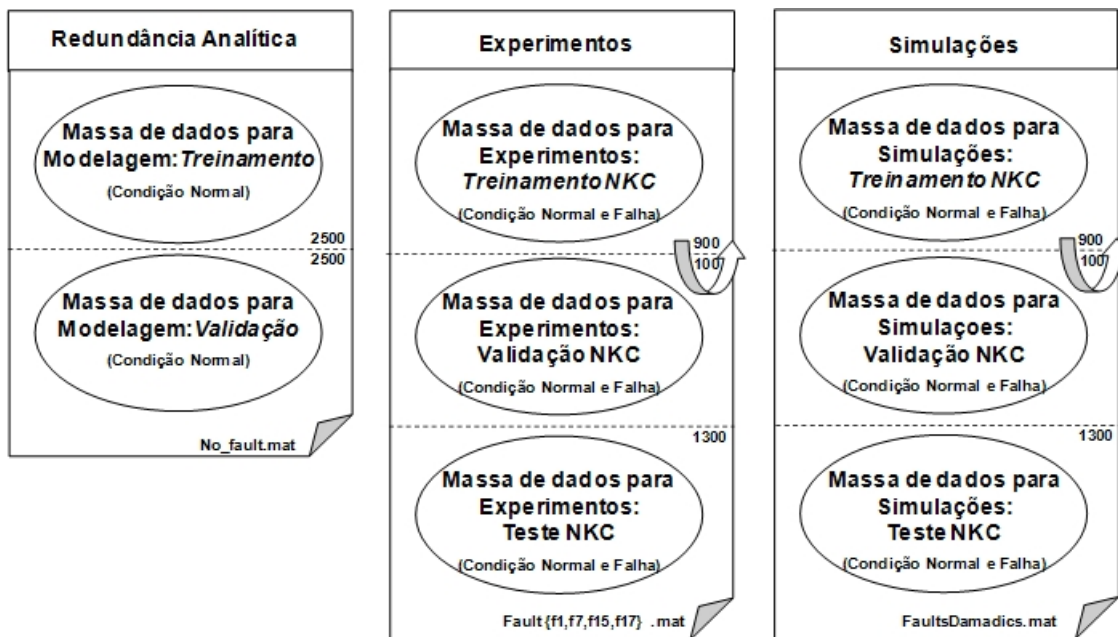


FIGURA 3.16 – Massas de dados geradas para a aplicação do algoritmo DF-NKC no *benchmark* DAMADICS.

3.4.2 Definição do Modelo de Redundância Analítica

A abordagem de detecção de falhas proposta utilizou redundância analítica para simulação do sistema dinâmico. Essa etapa foi baseada em:

- Modelagem - escolha de uma massa de dados, uma estrutura da representação do modelo e o treinamento do mesmo;
- Validação - depois de treinado o modelo, uma nova massa de dados foi fornecida para simulação da saída e se comparou com a saída real, permitindo monitorar o comportamento do resíduo do modelo e verificação de critérios de validação.

3.4.2.1 Modelagem

Na etapa de Modelagem foi utilizada como estrutura para treinamento dos dados o *Multi-Layer Perceptron* (MLP). O MLP possuiu as seguintes características que foram definidas empiricamente:

- Duas camadas: a camada de entrada e saída;
- Quatro neurônios com função de ativação TANSIG (tangente hiperbólica) na camada de entrada;
- Dois neurônios com função de ativação PURELIN (linear) na camada de saída;
- Treinamento utilizando a função TRAINLM fazendo o ajuste de pesos segundo algoritmo proposto por Levenberg-Marquardt;
- Desempenho medido com a função MSE (*Mean Square Error*).

No que diz respeito à massa de dados aplicada para o ajuste de pesos do MLP foram escolhidos 2.500 pontos de processo em operação normal. É importante salientar que o modelo gerado pelo MLP utilizou somente os dados de operação normal, ou seja, sem falhas. Portanto, o comportamento esperado do resíduo na ausência de falhas (diferença entre processo e saída do modelo) é que o mesmo esteja próximo de zero. A Figura 3.17 ilustra os primeiros 1.000 pontos da massa de dados de operação normal utilizados para modelagem do sistema dinâmico.

A Figura 3.18 ilustra as camadas do MLP e os valores de suas estruturas geradas na etapa de modelagem.




FIGURA 3.17 – Comparação do modelo com os dados em operação sem falhas do sistema dinâmico em estudo para a etapa de construção do modelo.




FIGURA 3.18 – Diagrama simplificado da rede neural utilizada. As variáveis de entrada e saída são detalhadas no item 2.3.1.2.

$$IW(1,1) = \begin{bmatrix} -44,7848 & 15,2394 & 1,3094 & -4,4656 \\ 8,8382 & -61,9705 & 216,2751 & 65,2473 \\ -40,1468 & 32,6456 & 24,0152 & 42,3434 \\ 32,4858 & -30,7896 & 41,79 & 62,4357 \end{bmatrix}$$

$$LW(2,1) = \begin{bmatrix} -0,065707 & 0,0073388 & -0,074369 & 0,088101 \\ 0,085571 & -0,02992 & 0,2211 & -0,079982 \end{bmatrix}$$

$$b(1) = \begin{bmatrix} 16,695 \\ -107,0308 \\ -31,901 \\ -26,4309 \end{bmatrix}$$

$$b(2) = \begin{bmatrix} 0,52836 \\ 0,59037 \end{bmatrix}$$

O erro quadrático médio durante a etapa de treinamento é mostrado na Figura 3.19. O parâmetro utilizado como critério de parada para o treinamento foi o erro percentual do MLP inferior a 0,1% ou 100 épocas de treinamento.




FIGURA 3.19 – Evolução do MSE em função do número de épocas para o sistema em treinamento.

3.4.2.2 Validação

Para a validação do MLP gerado utilizou-se uma base de dados disjunta da base de treinamento com mais 2.500 pontos. Uma vez validada a modelagem do sistema dinâmico, o modelo foi executado para os experimentos com o algoritmo DF-NKC conforme ilustra a Figura 3.15.

3.4.3 Definição dos Experimentos

Uma vez definido o modelo de redundância, o passo seguinte consistiu na análise sobre a sensibilidade e o ajuste dos parâmetros algoritmo DF-NKC para o *benchmark* em questão. A abordagem utilizada para análise de sensibilidade e definição de parâmetros do algoritmo DF-NKC foi feita por meio de *Design Of Experiments* (DOE) (Antony, 2006; Kleijnen, 2008). Além de permitir a análise da sensibilidade dos parâmetros, o DOE permitiu definir o conjunto de parâmetros de desempenho aperfeiçoado atuando como sintonizador dos parâmetros para as simulações. Os experimentos foram definidos por meio dos seguintes passos:

- Definiu-se quais parâmetros do algoritmo DF-NKC sofreriam alterações nas suas faixas de excursão durante os experimentos;

- Definiu-se que uma massa de dados seria utilizada para a avaliação de sensibilidade paramétrica do algoritmo DF-NKC e conteria um conjunto de falhas específicos;
- Definiu-se o limite superior e inferior para cada um dos parâmetros que sofreriam alterações durante os experimentos;
- Definiu-se que os experimentos fossem realizados 10 vezes para cada conjunto de parâmetros e a média e o desvio padrão índices de desempenho fossem registrados;
- Identificação dos melhores ajustes para os fatores usando análise de variabilidade para os parâmetros monitorados.

Para a definição dos experimentos foram utilizados todos os parâmetros do algoritmo DF-NKC totalizando 5 parâmetros. A Tabela 3.1 enumera os parâmetros e os valores (ou níveis) utilizados para os experimentos. Os valores foram escolhidos com base empírica de algumas execuções do algoritmo DF-NKC para a massa de dados de experimentos.

Fator	Algoritmo	Parâmetro	Nível	
			-	+
A	Inicialização de receptores de células NK	<i>TamanhoReceptor</i>	10	30
B	Inicialização de receptores de células NK	<i>ReceptoresCelula</i>	3	5
C	Algoritmo de Educação	<i>LimiarMaturacao</i>	40	60
D	Algoritmo de Educação	<i>TentativasAdicao</i>	3	5
E	Algoritmo de Educação	<i>MaximoCelulas</i>	3	5

TABELA 3.1 – Lista de parâmetros e níveis utilizados para a definição dos experimentos com o algoritmo DF-NKC

A massa de dados utilizada nos experimentos constituiu de dados das falhas abruptas de característica alta f1, f7, f15, f17. Essas falhas foram escolhidas uma vez que a geração dos parâmetros de simulação seria feita com base nos experimentos. Deste modo, a escolha dos parâmetros foi executada de forma a permitir um melhor desempenho, especificamente para as falhas citadas.

3.4.4 Execução dos Experimentos

A Tabela 3.2 evidencia os resultados dos indicadores de desempenho (média e desvio padrão) para cada um dos experimentos definidos (seção 3.4.3). É importante

mencionar que as falhas abruptas de característica alta f1, f7, f15, f17 constituíram a massa dados DAMADICS avaliada nos experimentos. Essas falhas foram escolhidas, uma vez que os resultados dessas simulações especificamente foram comparados com outros algoritmos encontrados na literatura.

Id	A	B	C	D	E	<i>dr</i> (%)	<i>fa</i> (%)
1	+	+	+	+	-	98,24 +- 2,38	0 +- 0
2	+	-	+	+	+	93,73 +- 4,23	0,01 +- 0,01
3	-	-	-	+	-	91,92 +- 5,79	0,24 +- 0,48
4	-	-	+	-	+	93 +- 4,65	0 +- 0
5	+	+	+	-	+	98,8 +- 1,39	0 +- 0
6	+	-	+	-	-	92,14 +- 5,29	0,09 +- 0,18
7	+	+	+	-	-	98,1 +- 1,32	0 +- 0
8	-	-	-	+	+	93,41 +- 4,64	0 +- 0
9	-	+	+	+	+	98,07 +- 2,26	0 +- 0
10	-	-	+	+	-	94,09 +- 3,95	0 +- 0
11	+	+	-	+	-	98,72 +- 1,09	0 +- 0
12	-	-	+	+	+	91,77 +- 5,57	0,6 +- 1,21
13	-	+	-	-	-	96,88 +- 2,37	0 +- 0
14	-	+	-	+	+	97,09 +- 4,04	0 +- 0
15	+	+	-	-	+	98,29 +- 1,32	0 +- 0
16	-	+	-	+	-	96,58 +- 2,51	0 +- 0
17	+	-	+	-	+	93,35 +- 4,58	0 +- 0
18	+	+	+	+	+	99,33 +- 1,32	0 +- 0
19	+	+	-	+	+	98,3 +- 1,44	0 +- 0
20	+	-	-	+	-	93,63 +- 4,54	0,03 +- 0,06
21	-	+	+	-	+	97,96 +- 1,41	0 +- 0
22	-	+	-	-	+	98,02 +- 1,38	0 +- 0
23	+	-	-	-	-	92,51 +- 5,07	0,09 +- 0,18
24	+	-	-	-	+	91,96 +- 5,49	0,09 +- 0,18
25	+	+	-	-	-	98,15 +- 1,27	0 +- 0
26	-	+	+	-	-	96,95 +- 2,82	0 +- 0
27	-	-	-	-	+	92,74 +- 4,89	0 +- 0
28	+	-	+	+	-	92,08 +- 5,26	0,09 +- 0,18
29	-	+	+	+	-	97,83 +- 1,49	0 +- 0
30	-	-	+	-	-	92,81 +- 4,94	0,03 +- 0,05
31	+	-	-	+	+	92,98 +- 4,73	0 +- 0
32	-	-	-	-	-	92,54 +- 5,18	0,09 +- 0,18

TABELA 3.2 – Lista de experimentos executados com os resultados médios e desvio padrão para os índices de desempenho do DAMADICS para 10 execuções para cada tipo de falha. O valor dos níveis de cada um dos parâmetros foi definidos na Tabela 3.1.

3.4.4.1 Análise de Sensitividade Paramétrica

De acordo com os dados da Tabela 3.2, foi executada análise de sensibilidade dos efeitos de cada um dos parâmetros do algoritmo DF-NKC em seu desempenho. Os efeitos para os dois índices de desempenho do DAMADICS encontram-se nas Figuras 3.20 e 3.21. Para a geração dos gráficos foi utilizado o aplicativo Minitab versão 15. A Figura 3.20 mostra que o parâmetro *TamanhoReceptor* (A) tem o maior efeito sobre o indicador de desempenho *dr*. Logo, uma alteração do nível (-) para o nível (+) do parâmetro *TamanhoReceptor* (A) trará ganho na média do índice *dr*, sendo as demais variações dos parâmetros relativamente menos sensíveis se comparadas ao parâmetro A.




FIGURA 3.20 – Análise de efeitos principais para os experimentos executados para o índice de desempenho *dr*.

Analogamente, a Figura 3.21 evidencia os efeitos dos parâmetros do algoritmo DF-NKC no índice de desempenho *fa*. A Figura 3.21 mostra que os parâmetros que possuem maior efeito em *fa* em ordem decrescente são: *TamanhoReceptor*(A), *ReceptoresCelula*(B), *TentativasAdicao*(D).

O efeito normalizado dos pesos para cada um dos parâmetros e suas combinações encontra-se na Figura 3.22. Observam-se os fatores e as interações (combinações de fatores) significantes usando grau de confiança de 95% para a variável *dr*, conforme mostrado

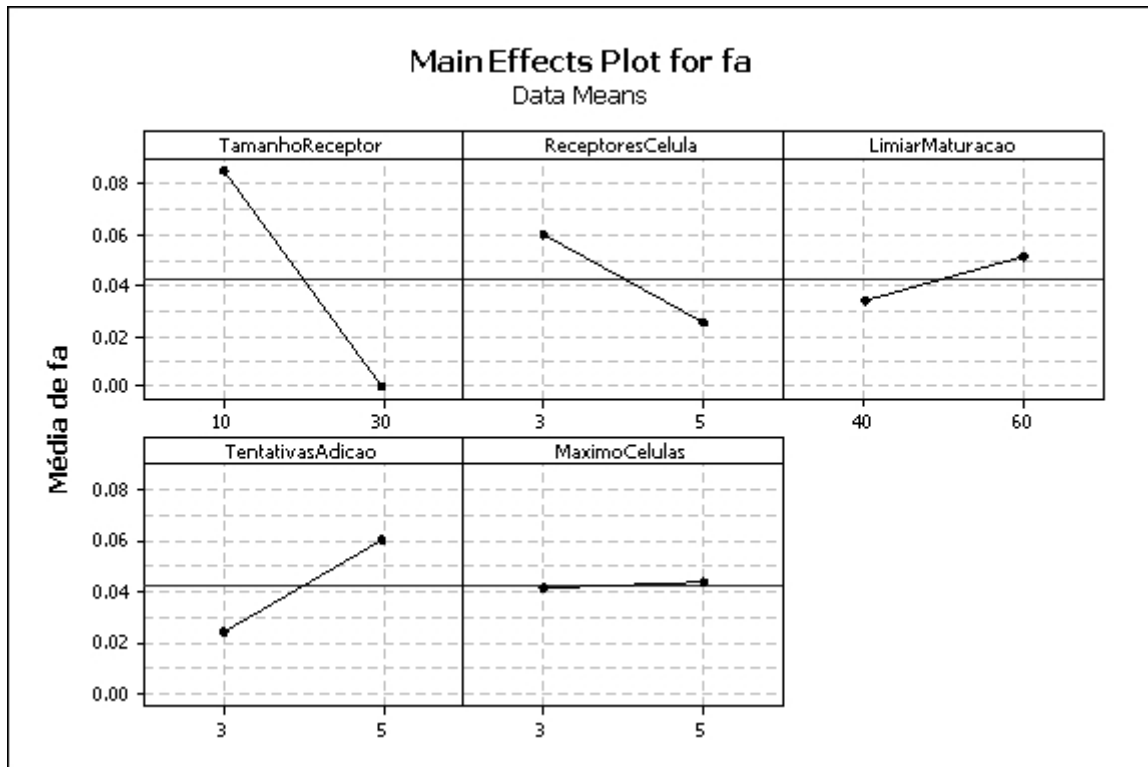


FIGURA 3.21 – Análise de efeitos principais para os experimentos executados para o índice de desempenho *fa*.

pela linha de corte de significância estatística. O fator A (*TamanhoReceptor*) foi o mais significativo seguido da interação AB (*TamanhoReceptor * ReceptoresCelula*), pelo fator B (*ReceptoresCelula*), pela interação BDE (*ReceptoresCelula * TentativasAdicao * MaximoCelulas*) e pela interação BCD(*ReceptoresCelula * LimiarMaturacao*).

A ocorrência de interação com efeitos estatisticamente significantes (especialmente para AB) impõe a necessidade de análise das interações. As interações de segunda ordem e encontram-se na Figura 3.23.

3.4.4.2 Definição de Ajuste Aperfeiçoado dos Fatores

Baseado nas análises e discussões do item 3.4.4.1, pode-se concluir que dentre os parâmetros analisados nos experimentos propostos, o parâmetro A é o que tem mais importância no índice de desempenho *dr*. Além disso, os fatores AB, BDE, BCD também influenciam este índice de desempenho.

O fator A foi escolhido com o valor de 30 (nível +) uma vez que melhora simultaneamente os dois índice de desempenho do *benchmark* DAMADICS além de ter maior significância na resposta de *dr*. O fator B foi escolhido o valor de 5 (nível +) por raci-




FIGURA 3.22 – Gráfico de pareto para cada um dos parâmetros e o efeito de seus pesos com grau de confiança igual a 95%

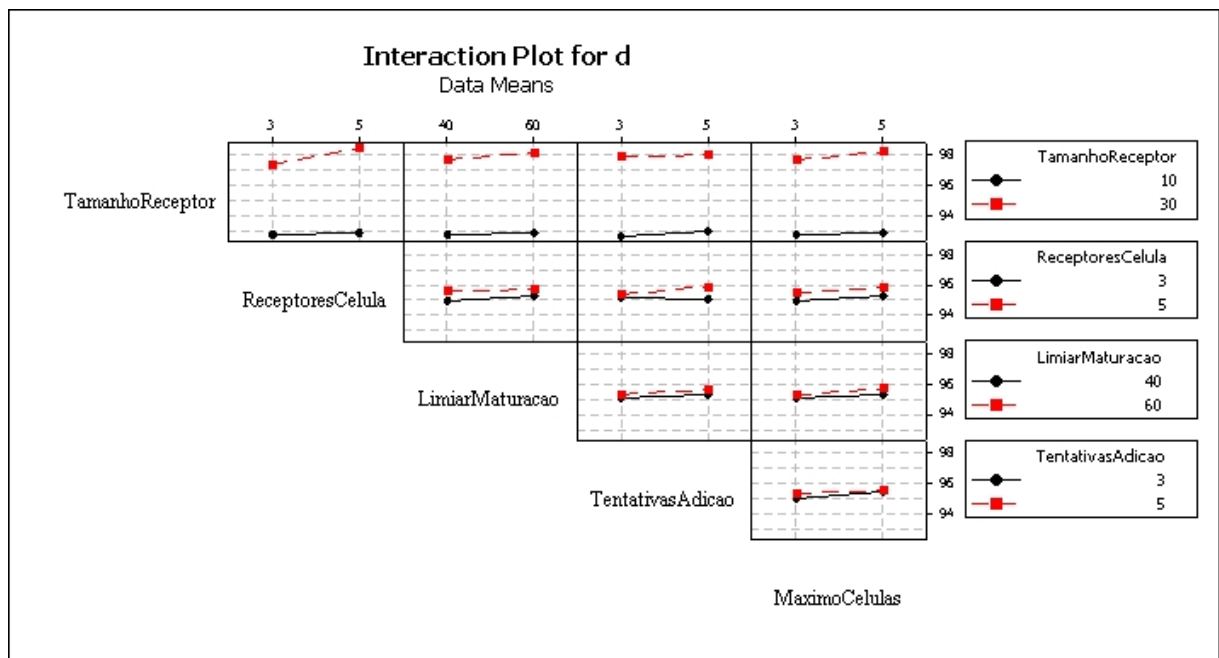


FIGURA 3.23 – Gráfico de interações entre os parâmetros e seus efeitos.

ocínio análogo a definição do fator A. Além disso, o nível (+) foi escolhido uma vez que ele interage com o fator A de forma a aumentar a média de dr . O fator C foi escolhido com o valor de 40 (nível -) ao passo que no gráfico de interações com BC praticamente não alterar o índice dr e reduz a média do indicador fa , com raciocínio análogo foram definidos os parâmetros D e E com o valor de 3 (nível -) (Tabela 3.3).

Id	Algoritmo	Parâmetro	Valor
A	Inicialização de receptores de células NK	<i>TamanhoReceptor</i>	30
B	Inicialização de receptores de células NK	<i>ReceptoresCelula</i>	5
C	Algoritmo de Educação	<i>LimiarMaturacao</i>	40
D	Algoritmo de Educação	<i>TentativasAdicao</i>	3
E	Algoritmo de Educação	<i>MaximoCelulas</i>	3

TABELA 3.3 – Lista de parâmetros e níveis utilizados para a definição das simulações com o algoritmo DF-NKC

3.4.5 Execução da Simulações

O algoritmo DF-NKC foi executado para os parâmetros que geraram um desempenho aperfeiçoado (vide Tabela 3.3) para a massa de dados definida durante os experimentos. As execuções do algoritmo DF-NKC utilizaram o método de validação cruzada k-pastas com $k=10$ (Figura 3.24).



FIGURA 3.24 – Validação cruzada em k-pastas com $k=10$

Como apenas uma execução de validação cruzada pode não ser suficiente para obter uma estimativa confiável do erro, o desempenho global do DF-NKC foi calculado como sendo a média de 10 execuções da validação cruzada. A média e o desvio padrão das execuções foram monitorados durante a execução das simulações. Com intuito de comparar o desempenho do DF-NKC a outros métodos existentes na literatura também aplicados ao *benchmark* da DAMADICS, os índices de desempenho descritos por Bartys

et al. (2006) foram calculados. As Tabelas 3.4 e 3.5 evidenciam o desempenho médio algoritmo DF-NKC sintonizado com os parâmetros de melhor ajuste definidos pela análise de sensibilidade (Tabela 3.3) para o conjunto de dados do DAMADICS de falhas abruptas e incipientes.

Id	Alta		Média		Baixa	
	<i>dr</i> (%)	<i>fa</i> (%)	<i>dr</i> (%)	<i>fa</i> (%)	<i>dr</i> (%)	<i>fa</i> (%)
f1	98,3 +- 1,1	0 +- 0	89,7 +- 3	0 +- 0	62,4 +- 5,5	12,8 +- 17
f7	98,5 +- 1,2	0 +- 0	98 +- 0	0 +- 0	98 +- 0	0 +- 0
f8	82,3 +- 13	3,66 +- 9,3	76,6 +- 15	5,85 +- 12	78,1 +- 15	7,35 +- 14
f10	89,5 +- 0,8	0 +- 0	81,2 +- 4,1	7,68 +- 7,8	77,2 +- 8,1	1,45 +- 3,3
f12	58,2 +- 44	6,06 +- 13	53,9 +- 44	9,21 +- 19	69,1 +- 31	12,4 +- 21
f14	86,7 +- 12	1,24 +- 3,4	83,1 +- 14	0 +- 0	84,3 +- 13	0 +- 0
f15	98,7 +- 2,8	0 +- 0	-	-	-	-
f16	76,9 +- 1,6	4,92 +- 3,9	71,6 +- 15	7,28 +- 10	82,1 +- 14	0 +- 0
f17	95,9 +- 5,6	0 +- 0	-	-	-	-

TABELA 3.4 – Desempenho do algoritmo DF-NKC com média e desvio padrão para 10 execuções usando validação *10-pastas* para cada um dos cenários de falhas abruptas explorados pelo DAMADICS.

Id	Índices de Desempenho	
	<i>dr</i> (%)	<i>fa</i> (%)
f2	42 +- 48	0,711 +- 1,8
f3	30 +- 48	0 +- 0
f4	11,6 +- 10	0 +- 0
f5	40 +- 52	0 +- 0
f6	30 +- 48	0 +- 0
f9	50 +- 53	0 +- 0
f11	21 +- 37	3 +- 7,2

TABELA 3.5 – Desempenho do algoritmo DF-NKC com média e desvio padrão para 10 execuções usando validação *10-pastas* para cada um dos cenários de falhas incipientes explorados pelo DAMADICS.

3.4.6 Discussão e Análise de Resultados

Essa seção discute os resultados das simulações e compara os resultados com outros algoritmos encontrados na literatura.

3.4.6.1 Discussão das Simulações

A Tabela 3.4 mostrou que para todas as falhas o índice de detecção foi superior a 75% exceto a falha abrupta “f12”. Para a falha citada, o desempenho inferior deveu-se ao modelo de redundância que não apresentou diferença significativa para a condição com e sem a falha. Com os dados da Tabela 3.4 ainda é possível constatar que para os três cenários de falhas abruptas (alta, média e baixa) o algoritmo DF-NKC obteve indicadores de desempenho distintos para um mesmo tipo falha. Em média, apresentou melhor desempenho para as falhas abruptas altas e pior para abruptas baixas conforme evidencia o gráfico da Figura 3.25 ilustrando o decaimento da média de dr e aumento da média de fa .




FIGURA 3.25 – Gráfico de médias para execuções das simulações de falhas abruptas gerados com dados da Tabela 3.4. Para cada tipo de falha são apresentadas as médias de dr e fa .

O resultado pode ser explicado pela natureza da falha abrupta alta que permite uma separabilidade de resíduo mais bem definida que as falhas abruptas médias e baixas gerando portanto uma separabilidade maior para a detecção. Outro fato que contribuiu para o melhor desempenho das falhas abruptas, especialmente para as altas foi o critério utilizado para definição da faixa de parâmetros do algoritmo DF-NKC. Percebe-se ainda que além de apresentar melhor dr e fa para as falhas abruptas altas “f1”, “f7” e “f15” e “f17” as simulações também apresentaram menor variabilidade para dr nas falhas “f1”, “f7” e “f15” do que as demais falhas abruptas como evidencia a Figura 3.26.

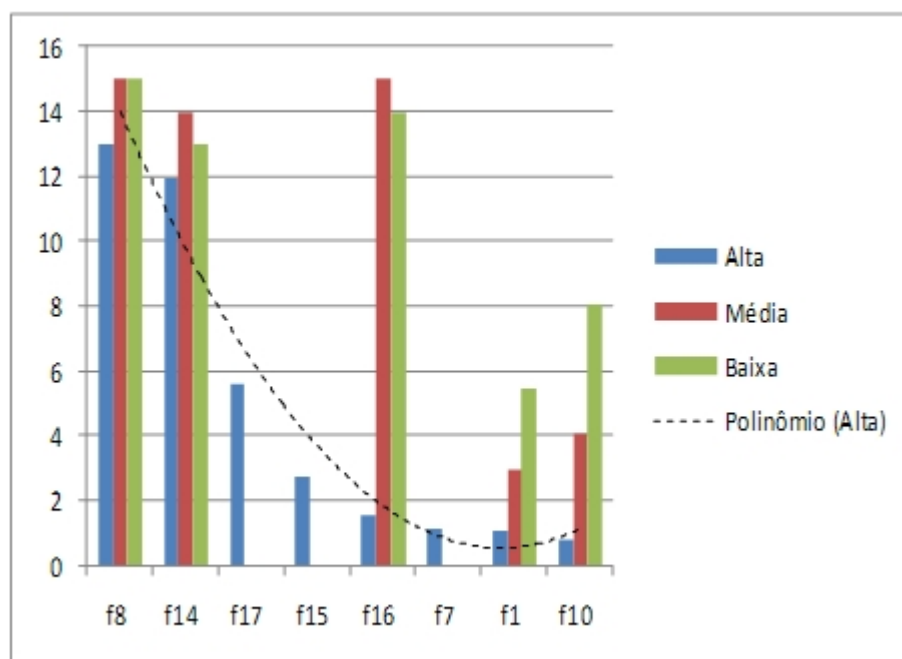


FIGURA 3.26 – Pareto de desvios padrões das taxas de detecção dr por tipo de falha abrupta com linha de tendência polinomial de 2 ordem para dr para as falhas abruptas altas. Dados fornecidos pela Tabela 3.4 e 3.5.

A Tabela 3.5 mostrou que para falhas incipientes o algoritmo DF-NKC alcançou um dr médio de 32,08% com falsos alarmes fa médios de 0,53%. Para falhas do tipo incipiente, o desvio padrão associado, principalmente a dr foi significativamente maior que os gerados pelas falhas abruptas.

3.4.6.2 Comparativo de resultados

Nesta seção os resultados encontrados na literatura para a detecção de falhas no *benchmark* desenvolvido pela DAMADICS são comparados com o desempenho do algoritmo DF-NKC. Os dados das simulações relativas a falhas abruptas altas foram gerados da mesma maneira descrita em Previdi and Parisini (2006). A Tabela 3.6 apresenta uma comparação entre os cenários de falha abrupta de intensidade alta que ambos os métodos foram capazes de detectar.

Analisando as falhas “f1”, “f7” e “f15” o algoritmo DF-NKC obteve maior taxa de detecção do que o algoritmo de Previdi and Parisini (2006) e próximas dos resultados publicados por Lemos Paim (2007), com o mesmo índice de alarmes falsos. Comparando as avaliações para a falha “f17”, verificou-se que a taxa de detecção do algoritmo DF-NKC é inferior a do algoritmo de Previdi and Parisini (2006) com a mesma taxa de alarmes

Id	DF-NKC		Previdi and Parisini (2006)		Lemos Paim (2007)	
	<i>dr</i> (%)	<i>fa</i> (%)	<i>dr</i> (%)	<i>fa</i> (%)	<i>dr</i> (%)	<i>fa</i> (%)
f1	98,3	0	55,0	0	98,22	0
f7	98,5	0	60,0	0	98,89	0
f15	98,7	0	85,0	0	98,89	0
f17	95,9	0	98,0	0	98,89	0

TABELA 3.6 – Desempenho comparativo dos índices para o *benchmark* DAMADICS com os cenários de falhas abruptos de intensidade alta.

falsos. A diferença nas médias dos resultados do DF-NKC para o resultado de Previdi and Parisini (2006) pode ser atribuída à modelagem do sistema de redundância analítico ou mesmo ao algoritmo de detecção de falhas proposto. Este fato reforça a necessidade de um processo de modelagem do sistema dinâmico ser feita de forma apropriada (Aguirre, 2000).

3.4.6.3 Análise de Significância Estatística

Uma vez que os indicadores de desempenho do DAMADICS foram calculados para o algoritmo DF-NKC, é importante verificar se eles são estatisticamente significantes se comparados a outros algoritmos encontrados na literatura. A análise de significância estatística utilizou $(100 - dr)$ como índice de desempenho dos algoritmos. Foi considerada a comparação estatística de múltiplos classificadores (algoritmos) em múltiplas bases de dados. Neste caso, as base de dados foram representadas por um tipo de falha do DAMADICS.

Segundo Demsar (2006), os métodos estatísticos apropriados para esta comparação são: ANOVA ou o Teste de Friedman. O ANOVA (*ANalysis Of VAriance*) é baseado na premissa de normalidade das amostras e esfericidade. Ainda segundo Demsar (2006), muito provavelmente algumas destas premissas são violadas quando analisando o desempenho de algoritmos baseados em Inteligência Computational (IC). Seu equivalente não paramétrico, o teste Friedman é recomendado nesses casos (Demsar, 2006). Ainda, de acordo com García et al. (2008), citando Iman e Davenport, o teste de Friedman é conservador e recomenda-se ainda levar em consideração o teste Iman-Davenport. Desta forma, o teste de Friedman e o de Iman-Davenport foram aplicados. Entretanto, para pequenas amostras (menor que 6) esse método pode fornecer aproximações imperfeitas para o valor de p . Para amenizar essa limitação, os resultados das falhas abruptas altas f10, f14 foram

adicionados nesta análise.

A Tabela 3.7 mostra o resultados da aplicação dos testes de Friedman e Iman-Davenport para os algoritmos DF-NKC, Previdi and Parisini (2006) e Lemos Paim (2007). Evidenciou-se que existem diferenças estatísticas significativas entre os resultados observados. É interessante mencionar que no caso em questão ($\chi^2 = 7$) os dois testes estatísticos forneceram resultados iguais para o conjunto de dados utilizados.

Valor em χ^2	Valor de p	Valor em F_F	Valor de p
7	0,0302	7	0,0302

TABELA 3.7 – Resultados do teste de Friedman e o teste proposto por Iman and Davenport considerando $\alpha = 0,05$.

A função de *rank* médio do teste de Friedman é mostrada pela Tabela 3.8.

Nome do Algoritmo	<i>Rank</i> Médio (Demsar, 2006)
Algoritmo DF-NKC	11
Previdi and Parisini (2006)	17
Lemos Paim (2007)	8

TABELA 3.8 – Resultados da classificação média fornecida pelo teste de Friedman. O pós-teste de Nemenyi (Demsar, 2006) indicou o valor de diferença crítica de $CD_{Nemenyi} = 1,35$ $CD_{Bonferroni-Dunn} = 1,29$ e para $\alpha = 0,05$.

Usando o pós-teste de Nemenyi (Demsar, 2006) e o de Bonferroni-Dunn são obtidas as diferenças críticas para permitir uma comparação entre os *ranks* médios para o teste de Friedman. O desempenho dos classificadores mostrou ser significativamente diferente para os algoritmos em termos do índice de desempenho avaliado. De acordo com os testes executados, o algoritmo proposto por Lemos Paim (2007) foi classificado em primeiro lugar, seguido do algoritmo DF-NKC e em terceiro lugar, o algoritmo proposto por Previdi and Parisini (2006).

Deve-se ressaltar que o algoritmo DF-NKC apresentou desempenho compatível ou superior aos algoritmos encontrados na literatura, evidenciado que a abordagem proposta é promissora para o problema de detecção de falhas.

Capítulo 4

Detecção de Falhas Inspirada no Modelo do Perigo

“One thing I have learned in a long life: That all our science, measured against reality, is primitive and childlike and yet, it is the most precious thing we have.”

Albert Einstein

Este capítulo apresenta uma nova abordagem imunoinspirada para detecção de falhas em sistemas dinâmicos: o algoritmo DF-DM (Detecção de Falha inspirada no Modelo do Perigo). Descrevem-se as inspirações imunes e as simplificações que caracterizam o novo SIA para detecção de falhas. A abordagem proposta é aplicada no *benchmark* da DAMADICS e os resultados são analisados.

4.1 Inspirações Imunes

O algoritmo DF-DM é baseado no Modelo do Perigo proposto por Matzinger (2002) e no modelo matemático da resposta das células *natural killer* (NK) descrito por De Pillis et al. (2005). Cada um destes temas é brevemente revisto nas seções seguintes. Deve ser mencionado que esta tese não objetiva defender o Modelo do Perigo ou a SNS (*Self Non-Self*). O foco foi dado na inspiração em abordagens imunoinspiradas para detecção de falhas.

4.1.0.4 Modelo do Perigo

Há mais de 50 anos imunologistas embasam pensamentos, experiências e tratamentos clínicos na idéia de que as funções do sistema imune fazem uma distinção entre próprio (relacionados com moléculas que pertencem ao organismo) e não próprio (relacionados com as moléculas externas ao organismo) (Forrest et al., 1994a; Das et al., 2008). Na última década um modelo se tornou popular entre os imunologistas: o Modelo do Perigo - para uma visão mais detalhada consulte (Matzinger, 2001, 2002). Este modelo buscou aprimorar pontos que os demais não explicavam. Um exemplo são as doenças autoimunes e alguns tipos de tumor onde o Sistema Imune (SI) responde ao próprio ou em casos de transplantes de sucesso, aonde não há resposta contra o não próprio. É importante dizer que o modelo não é completo, não explicando todas as interrogações existentes. Entretanto, esse modelo discute modelos que podem apoiar a concepção de SIAs, especialmente focados na detecção de falhas.

A proposição central do Modelo do Perigo é que o SI responde em função do senso de perigo ou danos causados e não em função do que é não próprio. Matzinger (2002) propõe uma nova visão no que diz respeito aos mecanismos da resposta imune: a ativação do SI é explicada por meio de sinais de perigo ou alarmes de células danificadas, como, por exemplo, as células expostas a patógenos, toxinas, danos mecânicos dentre outros motivos.

Essa visão nasce da observação de que não é necessário um ataque ou uma invasão de uma substância externa para início da resposta imune. Neste modelo, o perigo é medido pelo senso de dano ou avaria causada nas células, indicadas por sinais de perigo liberados durante a morte anormal da célula. De acordo com o Modelo do Perigo, a morte celular anormal é devida a uma ameaça ao organismo, que pode ser interna ou externa ao mesmo. Nesta visão, portanto, a resposta imune pode ser causada seja por um agente infeccioso ou não infeccioso.

No contexto imune descrito, APCs (*Antigen-Presenting Cells*) são células que irão processar o sinal de perigo e estimular as células T. As APCs são ativadas por sinais de perigo a partir de células danificadas, como, por exemplo, aquelas expostas a agentes patogênicos, toxinas, danos mecânicos, e assim por diante. As APCs ativadas irão fornecer um sinal para ativar as células T auxiliares (Figura 4.1).

Observa-se que o Modelo do Perigo leva a um novo paradigma: o fato de ser externo não é suficiente para iniciar uma resposta imune. Além disso, o fato de ser próprio não




FIGURA 4.1 – De acordo com o Modelo do Perigo, apenas as células danificadas são capazes de liberar alarmes ou sinais de perigo. Fonte: (Matzinger, 2002).

é garantia de tolerância. Um resumo da evolução dos modelos imunes é apresentado na Figura 4.2. Este paradigma é interessante no contexto de detecção de falhas ao passo que a falha efetivamente não necessita ser um agente externo ao sistema como, por exemplo, uma perturbação - mas pode ser a consequência de variação de um parâmetro interno ao processo.

4.1.0.5 Modelo Matemático da Resposta das Células NK

Durante pesquisa bibliográfica verificou-se a existência de artigos que se utilizam de modelos matemáticos para descrever a resposta do SI a uma infecção ou a um tumor.

Na abordagem proposta pelo algoritmo DF-DM, foi utilizado o modelo matemático das células NK - *Natural Killer* - descrito por De Pillis et al. (2005). O modelo é capaz de determinar o número de células NK quando um tumor está presente no organismo. Deste modo, é possível estimar o número de células NK ativadas por meio de uma função de recrutamento de células e o tamanho do tumor resultante da interação entre as células NK e as células de tumor De Pillis et al. (2005). Esse modelo foi interpretado como um modelo de dano (F. Colucci and Leibson, 2002).

4.2 Entendendo as Inspirações para a Nova Abordagem

A abordagem descrita neste item foi baseada no Modelo do Perigo objetivando a detecção de anomalias em sistemas dinâmicos utilizando o modelo matemático validado do comportamento do SII, mais particularmente as células NK, em resposta a um tumor.

Segundo o Modelo do Perigo, sinais de alarme são gerados pelas células que morrem por necrose (morte não programada) enquanto que os sinais de perigo não devem ser enviados por células saudáveis ou por células normais em processo de morte apoptótica.

No contexto imune descrito pelo Modelo do Perigo (Figura 4.1), APCs (*Antigen-Presenting Cells*) são células que processarão o sinal de perigo e estimularão as células T *Helper*.

O Modelo do Perigo propõe que o SI reagirá aos sinais de perigo causados por danos causados às células. Logo, um modelo que explicasse como danos causados geram os sinais de perigo gerados seria útil, ou seja, como a transdução dos sinais de dano se refletem em perigo para SI ou vice-versa. Especificamente neste trabalho, a inspiração de processamento das APCs baseia-se nas células NK. O modelo de dano utilizado foi o modelo matemático proposto por (De Pillis et al., 2005). Esse modelo matemático estima o número de células tumorais (dano) baseando-se nos sinais resultantes das células NK.

Além disso, cabe mencionar que no SI existe uma grande diversidade de APCs, que irão interagir dinamicamente para definir a resposta imune como um todo. Deste modo, é importante que a interação entre essas células seja considerada no modelo proposto. Baseado nas características encontradas, essa tese aplica o Modelo do Perigo segundo os passos mostrados pelo modelo da Figura 4.3, a saber:

- Definição dos Sinais: segundo o Modelo do Perigo os sinais são gerados por mortes necróticas (não-programadas) das células;
- Transdução de Sinais: as APCs irão coletar o sinal e processá-lo;
- Resultado Imune Final: As APCs proverão sinais para estimular ou não células T *Helper* dependendo da intensidade do sinal APC.

A seção 4.3 detalha cada uma das etapas macro do Modelo do Perigo proposto por essa tese e as suas analogias com a detecção de falhas.

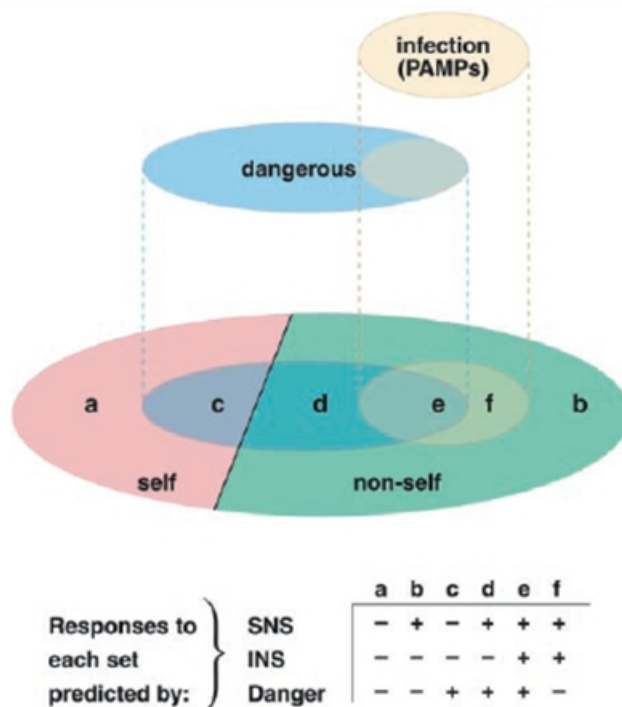


FIGURA 4.2 – Entendendo os paradigmas da resposta imune. Fonte: Matzinger (2002)




FIGURA 4.3 – Abordagem Imunoinspirada no Modelo do Perigo: uma visão em três macroetapas

4.3 Metodologia

O SIA proposto para detecção de falhas foi inspirado no Modelo do Perigo descrito no item 4.2. A fonte de inspiração foi a proposição de que a resposta imune não é guiada por um senso de estranheza, mas sim em um senso de perigo.

Como no Modelo do Perigo, os sinais de perigo devem ser definidos e tratados a fim de fornecer alarmes do comportamento do sistema dinâmico.

Esta seção apresenta as analogias entre o sistema proposto detecção de falhas e os mecanismos do Modelo do Perigo que inspiram o SIA proposto.

4.3.1 Definição dos Sinais

O primeiro passo proposto na detecção de falhas baseado no Modelo do Perigo foi selecionar um conjunto de entradas do sistema dinâmico cuja informação foi capaz de permitir a detecção de falhas. De acordo com o Modelo do Perigo as APCs processam os sinais de perigo ou de segurança (normalidade). Uma das principais fontes de sinais de perigo é a morte necrótica das células do SI. Neste ponto é importante distinguir os dois tipos de morte celular:

- Morte Celular por Apoptose: processo normal de morte celular (morte programada). Durante este tipo de morte, em geral, não há, ou há liberação em nível muito baixo de sinais de perigo;
- Morte Celular por Necrose: neste tipo de morte celular, são liberadas substâncias que são responsáveis pela geração de sinais de perigo.

No cenário de DF, em geral, existem três abordagens complementares que podem ser consideradas para definir os sinais de perigo e os sinais de segurança:

- Uso do sinal de resíduos como sinal de segurança: o resíduo é definido como a diferença entre a saída prevista do modelo e a saída real da planta (Figura 2.1). Este sinal é utilizado como sinal de segurança para indicar o nível de proximidade de uma condição segura. Neste caso, o processo deve ter dados normais para permitir a construção de um modelo de redundância. Uma vez que o sinal de resíduo é gerado por um modelo que reproduz o sistema dinâmico original é como se o próprio sistema gerasse este sinal (Figura 4.4);

- Usar limites conhecidos por especialistas como sinais de perigo: normalmente a engenharia de processo tem informações valiosas sobre o mesmo que podem ajudar a definir a condição de falha (por exemplo, temperatura de um fluido motor está abaixo de certo limite). Ocasionalmente, estes dados podem não estar disponíveis, dependendo do processo. Embora, em alguns casos, essas informações não estejam disponíveis, estes limites fornecem importantes informações sobre os sinais de perigo. A analogia com o Modelo do Perigo é que o senso de perigo pode ser incluído no modelo de detecção de falhas, o que significa que o sistema deve reagir apenas contra as ameaças reais ao organismo (Figura 4.4);
- Uso de condições de falhas conhecidas como sinais de perigo: é possível que algumas condições de falha do processo estejam disponíveis. Neste caso, alguns dados da falha podem ser usados para definir condições de falha conhecidas. A analogia com o DF-DM é o mesmo explicado no item Usar Limites Conhecidos por Especialistas como Sinais de Perigo (Figura 4.4).

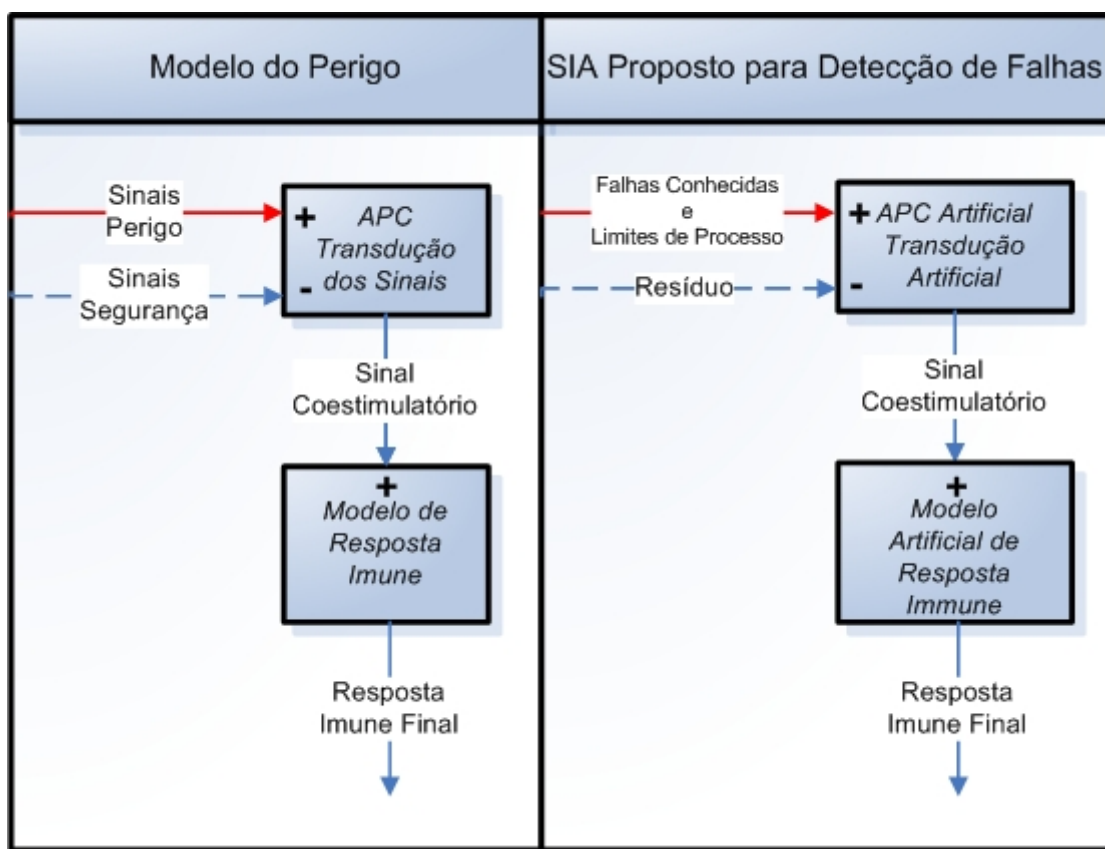


FIGURA 4.4 – Mapeamento dos sinais de segurança e perigo para o cenário de detecção de falhas usando o Modelo do Perigo.

4.3.2 Transdução de Sinais

Uma vez que os sinais de perigo e de segurança foram definidos, significa que o senso de perigo e o senso de segurança foram mapeados. O passo seguinte destinou-se a interpretar como o sinal coestimulatório foi gerado. Esta etapa foi denominada de Transdução dos Sinais. Neste caso, uma visão artificial do mecanismo de transdução do APC foi proposta, focada na detecção de falhas. De acordo com o DF-DM, o equilíbrio entre a apoptose e necrose afeta a ativação das APCs. Portanto, o equilíbrio entre a morte das células por apoptose e necrose parece ser crítico para a ativação do SI. Nesta seção é apresentado como as APCs foram modeladas para reagir as entradas com objetivo de gerar o sinal de coestimulação.

A Figura 4.5 e as seções seguintes detalham a estratégia de processamento das APC artificiais.

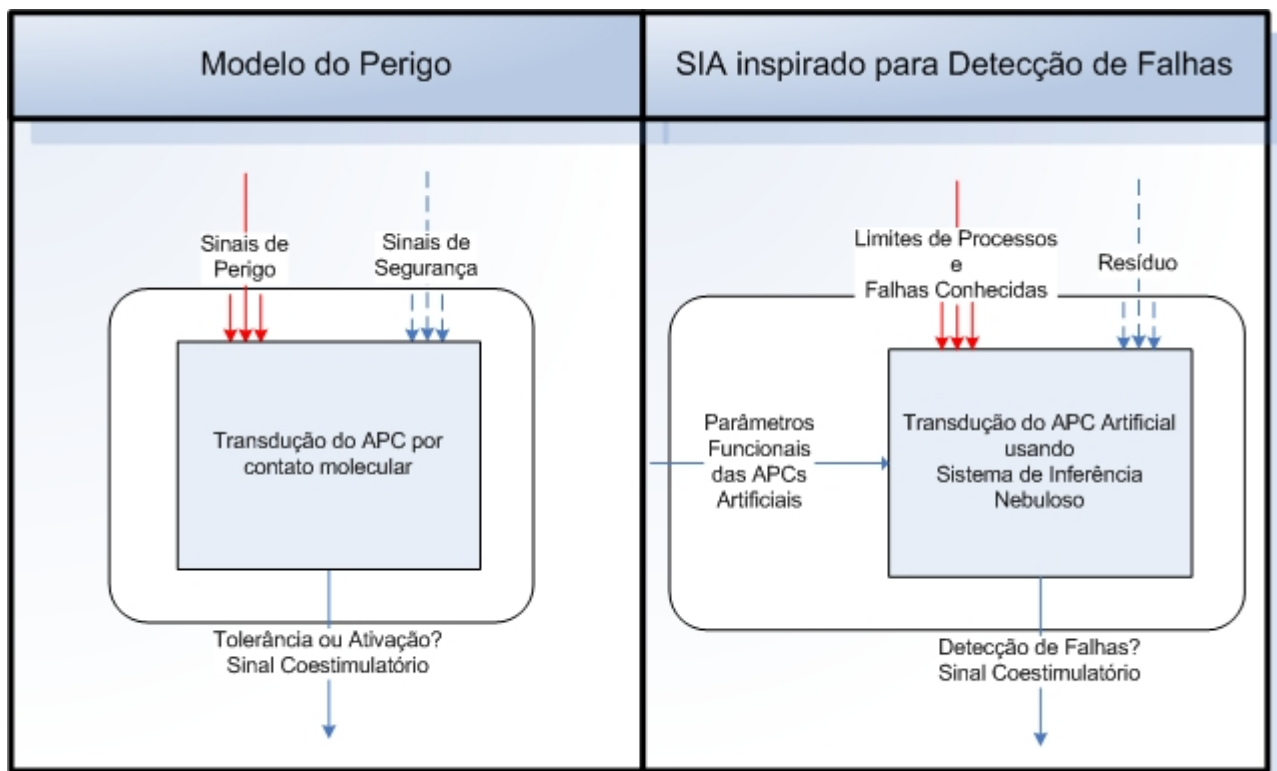


FIGURA 4.5 – Estratégia de processamento de sinais pelas APCs aplicados ao SIA de detecção de falha proposto.

4.3.2.1 Transdução de Sinais de Segurança

Neste tópico é apresentado como as APCs artificiais processam os sinais de segurança, no âmbito de detecção de falha para gerar o sinal de tolerância. A importância deste sinal no contexto da detecção de falhas é evitar a detecção de falsos positivos.

O sinal de segurança foi modelado como uma função do resíduo temporal $f(r,t)$, definida pela diferença entre a saída medida do sistema dinâmico e seu valor estimado na ausência de condições de falha. O resíduo, especificamente nesta condição, reflete as divergências que possam existir devido ao processo de modelagem. Portanto, um dos pressupostos fundamentais para gerar o senso de segurança é um modelo dinâmico adequado. A concepção deste modelo é essencial para proporcionar o senso de normalidade.

Devido aos erros de modelagem, espera-se que o resíduo não seja nulo mesmo no estado de normalidade. Este processo tem maior grau de analogia com a apoptose, ou seja, um pequeno resíduo é esperado, mesmo em condições normais. Em analogia ao processamento de sinais da APC, a APC Artificial utilizou um sistema de inferência nebuloso para o processamento de sinal de resíduos observando os seguintes pontos:

- Normalização de resíduo $[0,1]$: esse processamento evita problemas numéricos e facilita a definição de conjuntos nebulosos;
- Uso da média de resíduos gerada no processo de modelagem como um centro da função de pertinência trapezoidal com os seguintes parâmetros $[0 \ 0 \ 0 \ A]$ denominada “Normal”, onde A representa o valor médio do resíduo calculado durante a etapa de modelagem do sistema dinâmico;
- Uso do valor absoluto do maior resíduo durante o processo de modelagem do sistema dinâmico como um centro do conjunto nebuloso (parâmetro B da Figura 4.6) triangular a fim de definir limites para o senso de segurança provido pela APC. É interessante dizer que os conjuntos nebulosos “Normal” e “Max Normal” são complementares, como mostrado na Figura 4.6.

4.3.2.2 Transdução de Sinais de Perigo

Neste tópico apresenta-se como as APCs efetuaram o processamento de sinais de perigo que foram modelados, no âmbito de DF para gerar o sinal de perigo. A importância

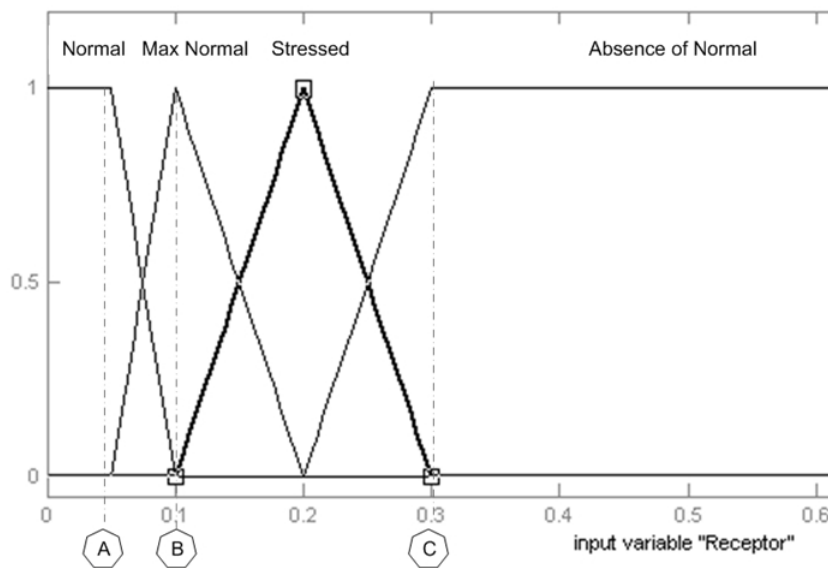


FIGURA 4.6 – Exemplo de transdução dos sinais de segurança por uma APC Artificial: Geração do senso de segurança pelo SIA proposto nesta tese.

deste sinal é evitar a detecção de falsos negativos. O processamento pelas APC Artificiais para geração do sinal de falha baseou-se nos seguintes passos:

- Uso do maior resíduo encontrado durante a presença de falha como centro do conjunto nebuloso triangular denominado “Absence of Normal” (parâmetro C da Figura 4.6), a fim de definir a região de perigo;
- O conjunto “Stress” será automaticamente definido como um conjunto nebuloso entre as funções de pertinência “Absence of Normal” e “Max Normal”.

4.3.2.3 Modelo Matemático de interação das Células NK

A fim de interpretar o sinal de coestimulação gerado pela APC, um modelo matemático (F. Colucci and Leibson, 2002) foi implementado. O modelo matemático a célula *Natural Killer* e suas interações com outras células do sistema imune.

A entrada do modelo matemático do sistema imune proposto é o sinal de coestimulação gerada pela APC Artificial. A saída é o tamanho do tumor estimado (fornecido em número de células de tumor) geradas pelo sinal de coestimulação (Figura 4.7).

Com base no modelo matemático imune, as células de tumor geradas foram categorizadas em um conjunto nebuloso com base no número de células de tumor e, consequentemente, a facilidade para superá-lo. A Figura 4.8 mostra os conjuntos nebulosos de o tumor com base no tamanho do mesmo.

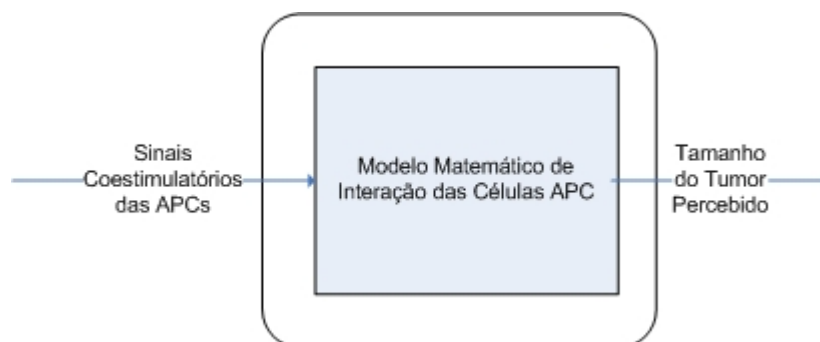


FIGURA 4.7 – Modelo Imune Artificial: Entradas e Saídas dos modelos.




FIGURA 4.8 – Conjuntos nebulosos representando o tumor percebido durante a resposta imune artificial.

4.3.3 Resposta Imune Final

Uma vez que o sinal de coestimulação foi gerado e o modelo imune artificial foi executado gerando o número de células tumorais, o passo seguinte foi a geração do resultado final imune, definindo as condições de alarme do SIA proposto para detecção de falhas.

A fim de gerar o resultado imune final, um sistema de inferência Mamdani foi utilizado. As regras aplicadas foram as seguintes:

1. Se (Artificial sentido APC é “Normal”) então (tumor enfrentado é “Easy”);
2. Se (Artificial sentido APC é “Max Normal”) então (tumor enfrentado é “Medium”);
3. Se (Artificial sentido APC é “Stress”) então (tumor enfrentado é “Hard”);
4. Se (Artificial sentido APC é “Absence of Normal”) e então (tumor enfrentado é “Very Hard”).

O sistema de inferência mapeia o domínio do sinal de coestimulação no domínio do resultado imune final representado por células tumorais. O método de detecção de falhas utilizou um limiar imune definido pela intensidade normalizada do tumor gerado. A intensidade foi definida como a soma das células tumorais normalizada pela soma do mínimo de células tumorais, como descrito pela Equação 4.1.

$$T_{intensidade} = \frac{\sum_0^{\infty} T(t)\delta t}{\sum_0^{\infty} T_{min}(t)\delta t} \quad (4.1)$$

Onde:

- T é o número de células tumorais em um instante de tempo t;
- T_{min} - representa o tumor mínimo, que foi definido como sendo o maior tumor atingido durante a fase de modelagem do sistema dinâmico utilizando dados de condição normal de operação.

O limiar de alarme imunológico (ITA) aplicado no SIA proposto foi definido como sendo de $T_{stressed}/T_{min}$. Onde $T_{stressed}$ é o tumor gerado por um sinal de coestimulação da pertinência *stress*. Deste modo, a condição de alarme é definida como: $T_{intensity} > ITA$.

4.4 Aplicação do Algoritmo DF-DM no *Benchmark*

DAMADICS

Esta seção descreve os passos para aplicação da metodologia proposta no item 4 no *benchmark* DAMADICS. A Figura 4.9 resume os principais passos detalhados nos itens seguintes. Uma vez que os passos dessa aplicação têm sobreposição com os passos detalhados na seção 3.4, eles serão devidamente identificados, não sendo novamente descritos nessa seção.

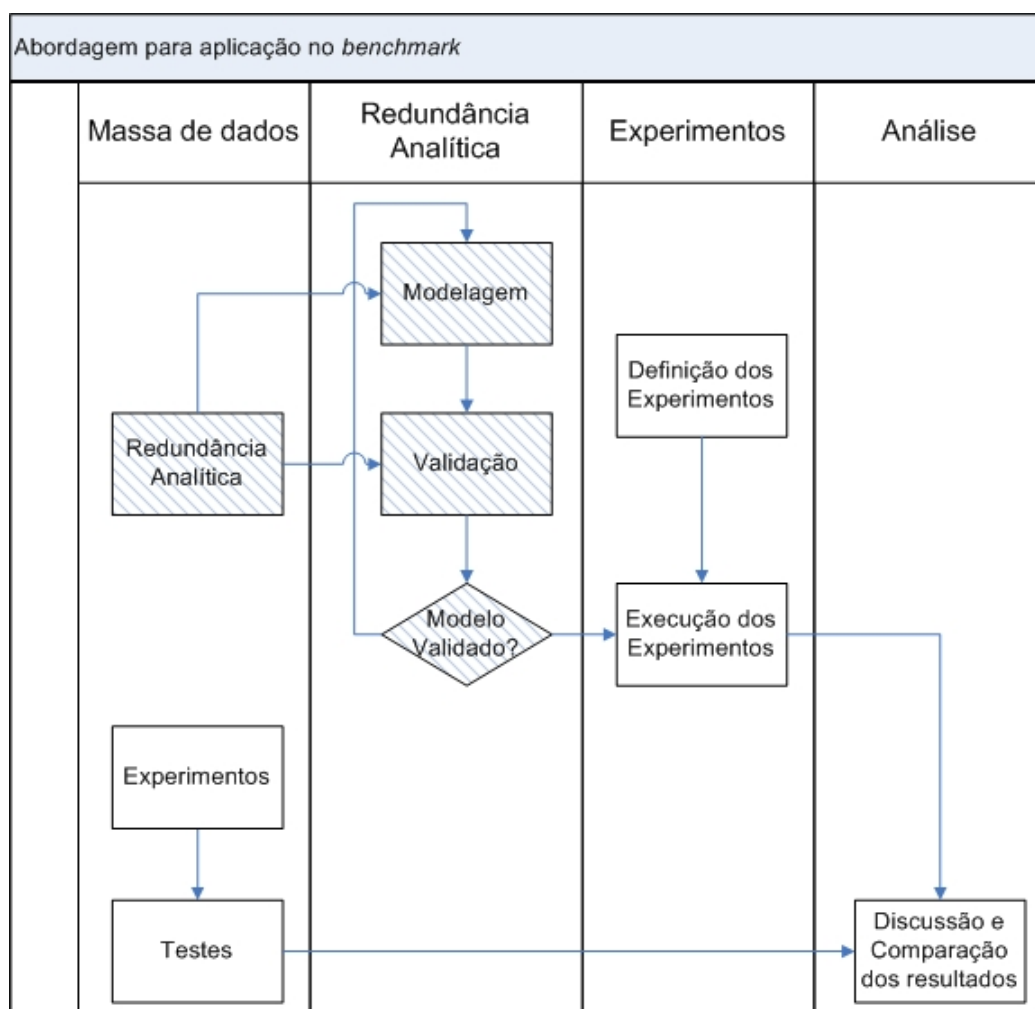


FIGURA 4.9 – Abordagem utilizada pela Tese com os principais passos envolvidos na aplicação do algoritmo DF-DM no *benchmark* DAMADICS.

4.4.1 Definição dos Experimentos

Uma vez definido a massa de dados (item 3.4.1) e o modelo de redundância (item 3.4.2), a definição dos experimentos foi feita da seguinte forma:

- Definiu-se que os parâmetros do modelo matemático imune seriam os propostos por De Pillis et al. (2005);
- Definiu-se que os experimentos fossem realizados 10 vezes para cada conjunto de parâmetros e a média dos índices de desempenho fossem registrados.

Para os experimentos utilizou-se o modelo de De Pillis et al. (2005) que descreve a dinâmica das alterações no SI causadas por um tumor. Ele considera as seguintes populações de células:

- células de tumor $T(t)$,
- o número de células NK ativas $N(t)$,
- células T específicas do tumor $L(t)$.

As populações de células são estimadas com uso em duas equações diferenciais, a saber:

$$\frac{dT}{dt} = aT(1 - bT) - cNT \quad (4.2)$$

onde a parcela:

- $aT(1 - bT)$ representa um crescimento do tumor caso não exista nenhuma resposta imune,
- $(cN)T$ representa as células mortas pelas células NK,
- a, b, c são parâmetros imunes ajustados para o comportamento humano. O parâmetro a é relativo a taxa de crescimento do tumor e b a capacidade de carga do tumor. O parâmetro c é referente a capacidade de morte de células de tumor por células NK.

$$\frac{dN}{dt} = \sigma - fN + \frac{gT^2}{h + T^2}N - pTN \quad (4.3)$$

onde a parcela:

- σ representa o número de células NK adicionadas ao sistema de defesa mesmo sem tumor,
- $-fN$ representa as células NK mortas,
- $\frac{gT^2}{h+T^2}N$ representa as células recrutadas devido a presença de células de tumor,
- $(pT)N$ representa o número de células NK mortas devido a presença de tumor,
- f, g, h e p são parâmetros imunes ajustados para representar o comportamento do Sistema Imune das células NK de pacientes humanos. O parâmetro f indica a taxa de morte das células NK. O parâmetro g indica a taxa máxima de recrutamento das células NK. O parâmetro h define o formato da curva de recrutamento pelas células NK. O parâmetro h define uma taxa de inativação das células NK devido as células de tumor. O parâmetro p indica a taxa de inativação das células NK devido ao tumor.

Para a definição dos experimentos foram utilizados os parâmetros descritos na Tabela 4.1 propostos por (De Pillis et al., 2005).

Parâmetro	Valor do Parâmetro	Unidade
a	5,14e-1	dia^{-1}
b	1,02e-9	$celula^{-1}$
c	3,23e-7	$celula^{-1} * dia^{-1}$
f	4,12e-2	dia^{-1}
g	2,5e-2	dia^{-1}
h	2,02e7	$celula^2$
p	1,00e-7	$celula^{-1} * dia^{-1}$
σ	1,3e4	$celula * dia^{-1}$

TABELA 4.1 – Valores dos parâmetros do modelo imune utilizados para simulação da resposta das APCs. Fonte: (De Pillis et al., 2005)

4.4.2 Execução dos Experimentos

A Tabela 4.2 evidencia o desempenho gerado pela aplicação do algoritmo DF-DM para o conjunto de dados de falhas abruptas (Alta, Média e Baixa) gerados no DAMA-DICS.

Id	Alta		Média		Baixa	
	dr(%)	fa(%)	dr(%)	fa(%)	dr(%)	fa(%)
f1	99,83	0,17	95	0,39	84	6,1
f7	99,89	0,11	93	0,11	89,1	0,11
f8	-	-	-	-	-	-
f10	99,89	0,11	89	0,11	85	15
f12	80,1	0,22	-	-	-	-
f14	-	-	-	-	-	-
f15	-	-	-	-	99,78	0,22
f16	99,72	0,28	-	-	-	-
f17	-	-	-	-	99,89	0,11

TABELA 4.2 – Desempenho do Algoritmo DF-DM para os cenários de falhas explorados no DAMADICS

4.4.3 Discussão e Análise de Resultados

Nesta seção os resultados para *benchmark* desenvolvido pela DAMADICS utilizando a metodologia proposta é comparado com o desempenho de outros algoritmos. Analisando os resultados obtidos para as falhas abruptas verifica-se que o sistema proposto não foi capaz de detectar as falhas do tipo f8, f12, f14, f16 (Média e Baixa). Verificando o resultados dos limites dos tumores calculados durante a execução dessas falhas nota-se que não foi possível determinar, com o modelo utilizado uma separação do sistema com e sem a falha, fazendo com que a falha fosse mapeada como sendo um receptor próprio, impossibilitando a detecção.

A Tabela 4.3 apresenta uma comparação entre os cenários de falha abrupta de intensidade alta que os métodos foram capazes de detectar. De maneira geral, o algoritmo DF-DM apresentou resultados relativamente superiores para *dr* do que os métodos encontrados na literatura aplicados a esse problema (Previdi and Parisini, 2006; Lemos Paim, 2007).

Id	DF-DM		(Lemos Paim, 2007)		DF-NKC	
	dr(%)	fa(%)	dr(%)	fa(%)	dr(%)	fa(%)
f1	99,83	0,17	98,22	0	98,3	0
f7	99,89	0,11	98,89	0	98,5	0
f15	99,78	0,22	98,89	0	98,7	0
f17	99,89	0,11	98,89	0	95,9	0

TABELA 4.3 – Desempenho comparativo do algoritmo DF-DM para os cenários de falhas abruptos de intensidade alta encontrados na literatura.

Comparando os resultados verifica-se que quantitativamente o sistema projetado

tem um desempenho ligeiramente superior ao de Lemos Paim (2007) com o custo da possibilidade de alarme falso superior as demais referências da literatura. Desta forma, mecanismos para reduzir os índices de alarme falso para essa metodologia devem ser estudados.

4.4.3.1 Análise de Significância Estatística

De forma análoga ao procedimento utilizado para a análise de significância estatística, os testes de Friedman e Iman-Davenport são mostrados na Tabela 4.4. Especificamente nesta seção os algoritmos: DF-DM, DF-NKC e o proposto por Lemos Paim (2007) são comparados em busca de significância estatística.

Analisando os dados da Tabela 4.4 a hipótese nula não pode ser rejeitada (o desempenho dos algoritmos é diferente), pois $p > \alpha$, para os dados em questão, nos testes executados não apresentam significância estatística.

Valor em χ^2	Valor de p	Valor em F_F	Valor de p
1,75	0,417	0,85	0,652

TABELA 4.4 – Resultados do teste de Friedman e o teste Iman-Davenport para $\alpha = 0,05$.

Considerando os resultados do teste estatístico utilizado, o algoritmo DF-DM apresentou desempenho compatível aos algoritmos encontrados na literatura, evidenciado que a abordagem proposta é promissora para o problema de detecção de falhas.

Capítulo 5

Detecção de Falhas Inspirada em Aprimoramentos no Algoritmo de Seleção Negativa

“Of all the mysteries in modern science, the mechanisms of self versus nonself recognition in the immune system ranks at or near the top”.

D. E. Koshland Jr.

O Capítulo 5 descreve um aprimoramento para o algoritmo da seleção negativa com codificação real - o algoritmo DF-Multioperacional e sua aplicação no contexto de detecção de falhas. O SIA para detecção de falhas é apresentado juntamente com suas inspirações imunes, motivações para aprimoramentos e metodologia. A abordagem proposta é aplicada no *benchmark* de acionamento de um motor de corrente contínua e os resultados são analisados.

5.1 Visão Geral dos Algoritmos de Seleção Negativa

Algoritmos de seleção negativa consistem em duas etapas: o treinamento ou sensoriamento, efetuado *off-line* e a classificação ou monitoramento executado de forma *on-line* como ilustra a Figura 5.1.

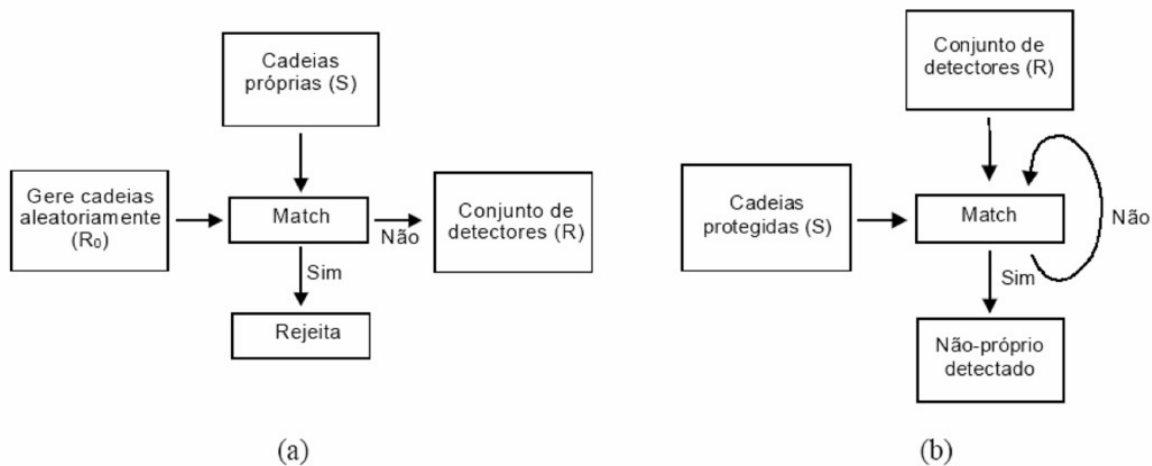


FIGURA 5.1 – Fluxograma do algoritmo de seleção negativa. (a) Geração de um conjunto válido de detectores (sensoriamento). (b) Monitoramento. Fonte: (de Castro, 2001).

Os detectores representam as células precursoras das células T que foram selecionadas por meio de comparação a pontos próprios (pontos de condição normal do sistema). Caso o detector se superponha a um ponto próprio, o mesmo deve ser descartado. A fase de treinamento utilizou somente pontos próprios (dados na condição normal). Os detectores foram gerados para cobrir a região complementar - denominada região não própria - análoga à região de falha. Os algoritmos de seleção negativa foram aplicados ao problema de detecção de anomalias onde a classe de dados normais é geralmente abundante se comparada com o volume de dados de anomalias ou falhas disponível dos sistemas industriais. Algumas propriedades do algoritmo de seleção negativa encontram-se descritas a seguir.

5.1.1 Complexidade Computacional

O algoritmo inicial de seleção negativa é inspirado no mecanismo onde novos detectores são aleatoriamente gerados e comparados a cada ponto próprio. Caso o detector se superponha ao ponto próprio, o candidato a detector é descartado e um novo é aleatoriamente gerado.

Uma dificuldade em termos de complexidade computacional nesta abordagem é percebida. Dados $|S|$ pontos próprios e $|N|$ não próprios para a geração de M detectores maturados, a complexidade no tempo aumenta exponencialmente com S e linearmente com M (Forrest et al., 1994b). Desta maneira, existe um custo exponencial de geração de detectores em relação ao tamanho do conjunto próprio.

5.1.2 Cobertura do espaço

Com a aplicação e análise do algoritmo de seleção negativa, novos problemas surgiram como, por exemplo, o problema dos buracos. Neste caso, esse problema refere-se a pontos não próprios que não foram cobertos pelos detectores durante a seleção negativa, deixando áreas não cobertas ou buracos, como ilustra a Figura 5.2.




FIGURA 5.2 – Problema dos Buracos: Na forma de círculos são representados os detectores e a região central mais clara representa o espaço próprio. Fonte: Balachandran (2005).

5.1.3 Codificação

Inicialmente o algoritmo de seleção negativa foi utilizado para detectar alterações em *strings* (Forrest et al., 1994b). Nas versões iniciais do algoritmo de seleção negativa o tamanho da *string* era arbitrário e eram divididas em segmentos menores - (*substrings*) - para verificar sua similaridade. Na representação binária, um conjunto de regras de verificação de similaridade podem ser utilizadas como a distância de Hamming, RCB (*R Contiguous Bits*) dentre outros. Na representação real, cada item é representado através de um vetor de números reais. A medida de diferença ou similaridade é baseada nos elementos numéricos do vetor. A representação real facilita a interpretação do problema, uma vez que o mesmo pode ser interpretado no seu domínio original.

No decorrer desta tese somente algoritmos de codificação real foram utilizados devido principalmente à facilidade para mapeamento do domínio do problema. No que diz respeito as métricas para cálculo de distância, somente a norma euclidiana foi utilizada.

5.2 Algoritmos de Seleção Negativa Preexistentes

Nas seções a seguir foram detalhados os dois algoritmos preexistentes que foram confrontados com o algoritmo DF-Multioperacional. O algoritmo de detectores de raios constantes e o V-Detector são explicados em detalhes nas seções a seguir.

5.2.1 Algoritmo de Detectores de Raio Constante

Na fase de treinamento, o algoritmo de raio constante baseia-se na geração aleatória de um conjunto de candidatos a detectores que são comparados com padrões próprios. Qualquer detector que se combine a um padrão próprio é descartado do conjunto de detectores. Na fase de classificação, caso o detector se combine a um padrão apresentado, o mesmo é classificado como não próprio, identificando uma anomalia (D. Dasgupta and Berry, 2004). O fluxograma representado pela Figura 5.3 evidencia os passos lógicos para a implementação deste algoritmo.

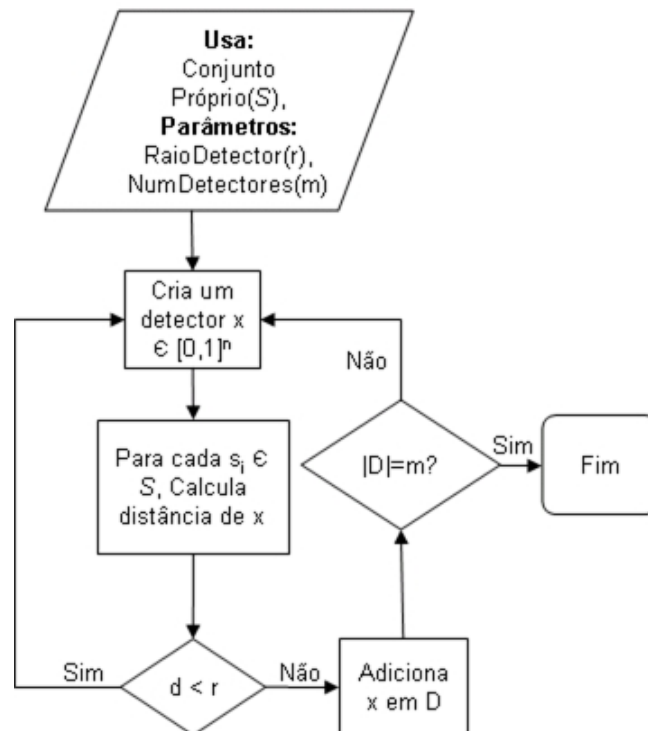


FIGURA 5.3 – Fluxograma de funcionamento do algoritmo de Raio Constante

Os principais fluxos da seleção negativa de raio constante são:

1. Define-se um conjunto de pontos denominado conjunto próprio (S) dentro de um universo de pontos (preferencialmente normalizados). Cada ponto avaliado, por

exemplo, o dado de um sensor, é alocado em uma dimensão do espaço de formas. Desse modo, em m dimensões, os dados estão em $[0,1]$;

2. Gera-se um conjunto de detectores D de tamanho dado pelo parâmetro $NumDetectores$, com raio constante fornecido pelo parâmetro $RaioDetector$ que não detecte (tenha sobreposição) nenhum ponto do conjunto S inicialmente gerado;
3. Apresenta-se os pontos do conjunto D ao conjunto que se deseja avaliar. Se algum ponto do conjunto avaliado se encontra dentro do raio de detecção de um detector de D , uma anomalia é gerada.

Observa-se que os parâmetros de ajuste do algoritmo de seleção negativa de raio constante são:

- $NumDetectores$: Número de detectores a serem gerados;
- $RaioDetector$: Constante real que indica o tamanho do raio região própria gerada.

5.2.2 Algoritmo V-Detector

O V-detector, ou algoritmo com detectores de raio variável foi inicialmente proposto em (González and Dasgupta, 2004) e apresenta uma evolução em relação ao algoritmo anterior: os detectores não possuem raio constante. Neste caso, o raio foi calculado em função da célula própria mais próxima. Além disso, o V-detector usou uma estratégia que privilegiou a adição de detectores que não fossem detectados no conjunto de detectores existentes e que possuam um raio relativamente maior (Figura 5.4).

Utilizando-se o V-Detector um dos problemas do algoritmo de raio constante é reduzido: o problema dos buracos. Isso se deve a geração de detectores tangentes à região própria (Ji and Dasgupta, 2004). No entanto, este algoritmo possui limitações já conhecidas do algoritmo de raio constante, como, por exemplo, a sobreposição dos detectores. Os principais parâmetros de controle do V-Detector são:

- c_0 : Cobertura estimada esperada;
- $NumDetectores$: Número de detectores a serem gerados.

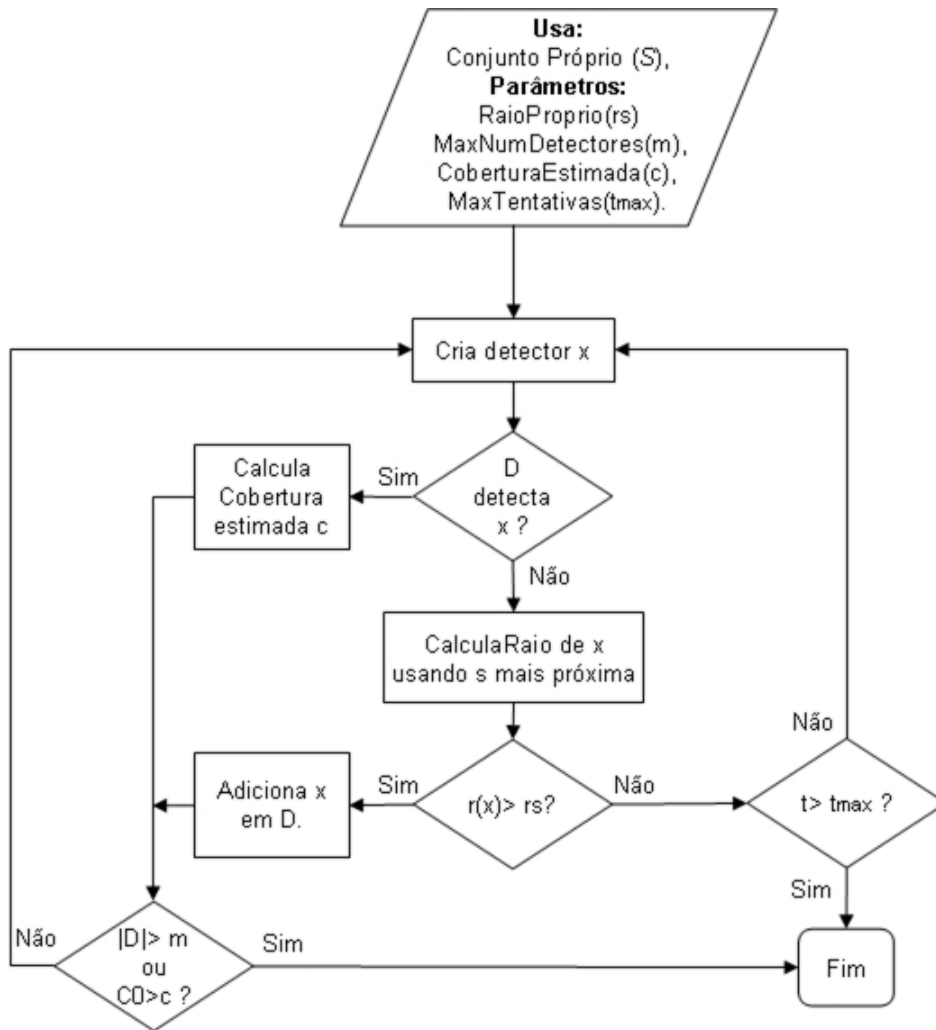


FIGURA 5.4 – Fluxograma de funcionamento do algoritmo V-detector.

5.3 Inspiração Imune e Motivação para Aprimoramentos

O algoritmo DF-Multioperacional foi desenvolvido buscando aprimorar os SIAs inspirados no modelo de seleção negativa. Este modelo propõe que o SIB necessita diferenciar as moléculas do seu corpo (próprias) e as moléculas externas (não próprias).

A seleção negativa descreve o processo no qual a interação de células precursoras do linfócito com o antígeno resulta na morte (deleção clonal) ou anergia (anergia clonal) deste (de Castro, 2001). O processo de seleção negativa ocorre no Timo (seleção tímica) para as células precursoras das células T. Na fase seguinte, elas são liberadas para circular no organismo. Quando estas estão em processo de maturação, aquelas que se combinam a substâncias próprias são eliminadas ou desativadas. Desta forma, a seleção negativa

tenta explicar que o SI é capaz de distinguir qualquer célula ou molécula externa ao organismo daquelas produzidas internamente. Foram encontrados na literatura, trabalhos que explicam em mais profundidade as analogias imunes do algoritmo de seleção negativa (Ji, 2006).

Os principais desafios dos algoritmos de seleção negativa são: a cobertura do espaço gerado pelo algoritmo e a complexidade computacional. A seção seguinte apresenta a nova proposição.

5.4 Metodologia

O algoritmo DF-Multioperacional foi desenvolvido com a finalidade de promover uma cobertura do espaço não próprio com maior eficiência, ou seja, o menor número de detectores, com o maior raio.

Para um melhor entendimento, serão expostas previamente as principais ferramentas operacionais adicionadas aos algoritmos de seleção negativa preexistentes. O número de ferramentas operacionais é o principal responsável pelos resultados sendo o motivador da denominação algoritmo DF-Multioperacional.

5.4.1 Ferramentas Operacionais

Cada detector aleatoriamente gerado pelo algoritmo passa por diversas etapas antes de ser considerado um detector maduro. As operações do algoritmo DF-Multioperacional são descritas a seguir.

O índice γ foi responsável por avaliar a maturação do detector, medindo sua sobreposição em relação aos outros detectores. Este índice foi definido por:

$$\gamma = \frac{r_{det} - r_{prox} + dist}{2 * r_{det}} \quad (5.1)$$

onde:

- r_{det} é o raio do detector;
- r_{prox} é o raio de outro detector em relação ao qual o primeiro está sendo avaliado;
- $dist$ é a distância entre os dois detectores.

Observa-se que quando $\gamma = 1$ os detectores são tangentes. Existe ainda, a operação de cálculo do raio do detector, dado por:

$$r_{det} = dist - r_{self} \tag{5.2}$$

Onde:

- r_{det} é o raio do detector;
- $dist$ é a distância entre o detector e a célula própria mais próxima;
- r_{self} o raio da célula própria.

Outra operação, consiste no movimento de detectores, dado por:

$$c_{novo} = c_{anterior} + \alpha * \frac{(c_{anterior} - c_{proximo})}{|c_{anterior} - c_{proximo}|} \tag{5.3}$$

Onde:

- c_{novo} como as novas coordenadas do detector;
- $c_{anterior}$ antigas coordenadas;
- α um fator exponencial, dependente do número prévio de tentativas para mover o detector;
- $c_{proximo}$ coordenadas da célula mais próxima.

A Figura 5.5 ilustra duas operações básicas do algoritmo DF-Multioperacional: cálculo do raio e o movimento de detectores.




FIGURA 5.5 – As operações básicas com os detectores: o cálculo do raio do detector e o movimento da célula detectora.

Além dessas operações, utilizou-se o decaimento exponencial ao raio, quando não se conseguiu alocar o detector, e o aumento do limite de sobreposição atuando como último recurso para se tentar alocá-lo.

5.4.2 Funcionamento

O algoritmo DF-Multioperacional atua criando detectores aleatórios e tentando alocá-los no espaço não próprio pelo princípio da seleção negativa e das suas ferramentas operacionais. A Figura 5.6 ilustra o fluxograma do algoritmo DF-Multioperacional.

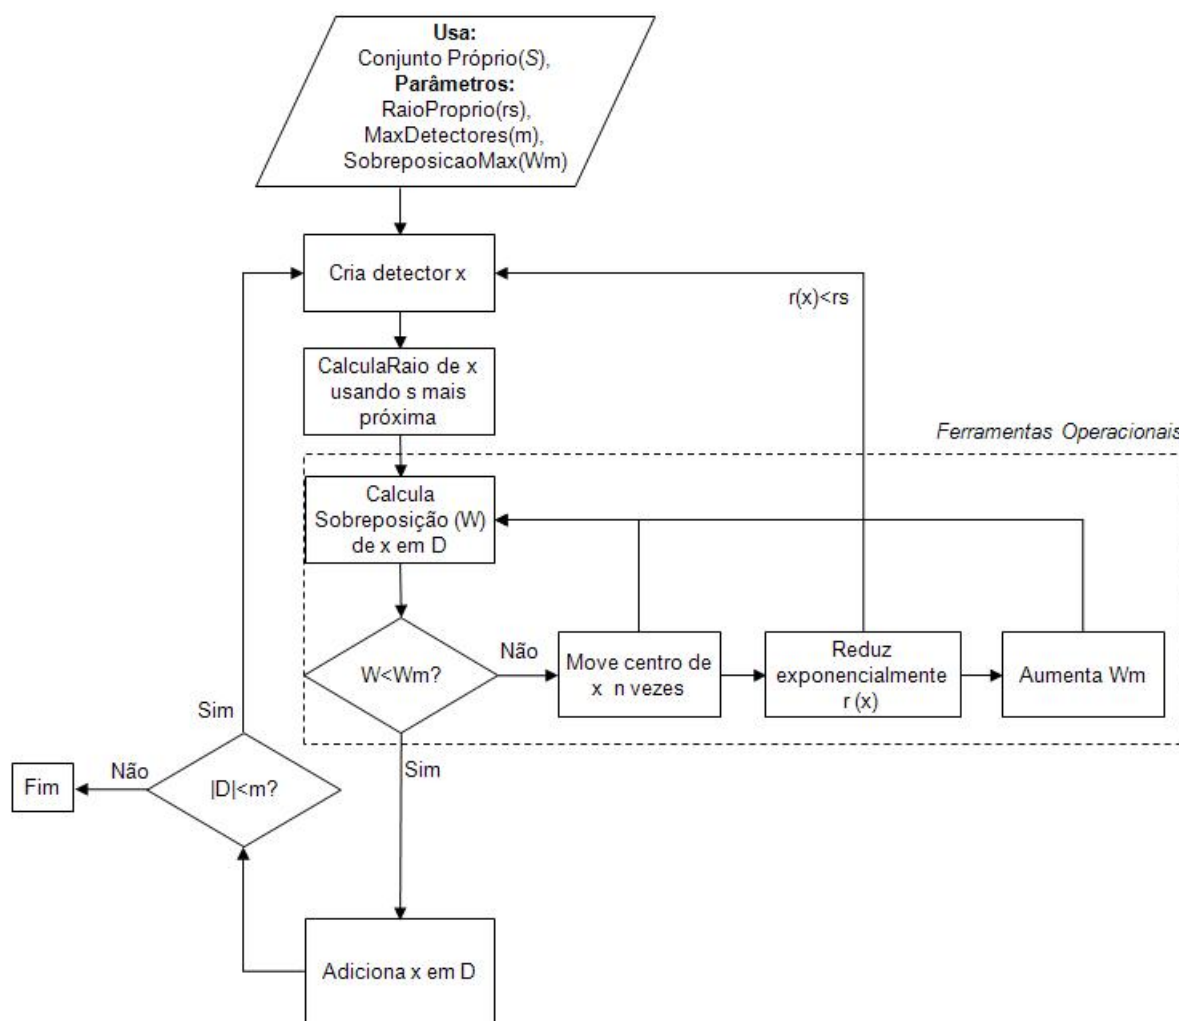


FIGURA 5.6 – Fluxograma de funcionamento do algoritmo DF-Multioperacional.

Desta maneira, após criar um detector aleatório e calcular seu raio em função da célula própria mais próxima, calcula-se a sua sobreposição. Caso esta esteja acima de um limite definido pelo parâmetro *SobreposicaoMax(Wm)*, o detector tem seu centro movido por um número finito de vezes. Caso esta ação não seja suficiente para redu-

zir a sobreposição a níveis aceitáveis, o raio do detector sofre sucessivos decaimentos segundo curva exponencial. Como último recurso, aumenta-se o limite de sobreposição $SobreposicaoMax(Wm)$ para tentar alocar o detector por t vezes.

O processo de criação de detectores continua até que se atinja um limite máximo de detectores ou que um número limitado de tentativas seja feito para aumento do limite de sobreposição.

5.5 Aplicação do Algoritmo DF-Multioperacional no *Benchmark* de Coroa Circular

O algoritmo DF-Multioperacional assim como os algoritmos de raio constante e V-detector foram implementados e executados para a massa de dados do *benchmark* de Coroa Circular.

Esse *benchmark* foi usado para permitir a validação das implementações dos algoritmos de seleção negativa e comparações de comportamentos de taxa de detecção e falso negativos. Para isso, definiu-se a base de dados, os experimentos sua execução e análise de resultados.

5.5.1 Definição da Base de Dados

A base de dados utilizada foi uma coroa circular com as seguintes características:

- Definiu-se que a coroa circular teve 150 pontos aleatórios gerados dentro dela;
- Para a validação dos conjuntos de detectores gerados por cada um dos algoritmos, foram apresentados outros 200 pontos, sendo metade dentro da coroa circular (região própria) e metade fora (região não própria).

5.5.2 Definição dos Experimentos

Uma vez definida a base de dados utilizada, o próximo passo consistiu na análise sensibilidade simplificada dos algoritmos DF-Multioperacional, *V-detector* e raios constantes para o *benchmark* em questão. A análise de sensibilidade foi feita por meio de

variação dos parâmetros e análise segundo a definição dos experimentos. Foram realizados experimentos considerando os três algoritmos de seleção negativa descritos para a simulação, implementados pelo autor. Os experimentos foram definidos por meio dos seguintes passos:

- Para análise de sensibilidade, os algoritmos foram executados para diversos raios próprios (intervalo de $[0,01 \ 0,10]$) com variação de 0,01 buscando entender a sensibilidade dos algoritmos em função do raio próprio escolhido;
- Para cada conjunto de detectores gerados foram calculados os índices de taxa de detecção de falhas, alarmes falsos e o tempo computacional;
- Para cada algoritmo, em cada valor de raio próprio, os índices foram calculados 100 vezes.

Alguns exemplos de execução no *benchmark* de coroa circular para os algoritmos de raios constantes, V-Detector e DF-Multioperacional (Figuras 5.7, 5.8, 5.9). O algoritmo DF-Multioperacional foi executado com os seguintes parâmetros nos experimentos:

- $CoberturaEstimada = 99,9\%$;
- $SobreposicaoPermitida = 50\%$.




FIGURA 5.7 – Exemplo de resultado com (a) 200 detectores e com (b) 500 detectores para r_{self} de 0,08. As células claras definem a região própria e as células escuras são os detectores criados pelo algoritmo de seleção negativa de raio constante.

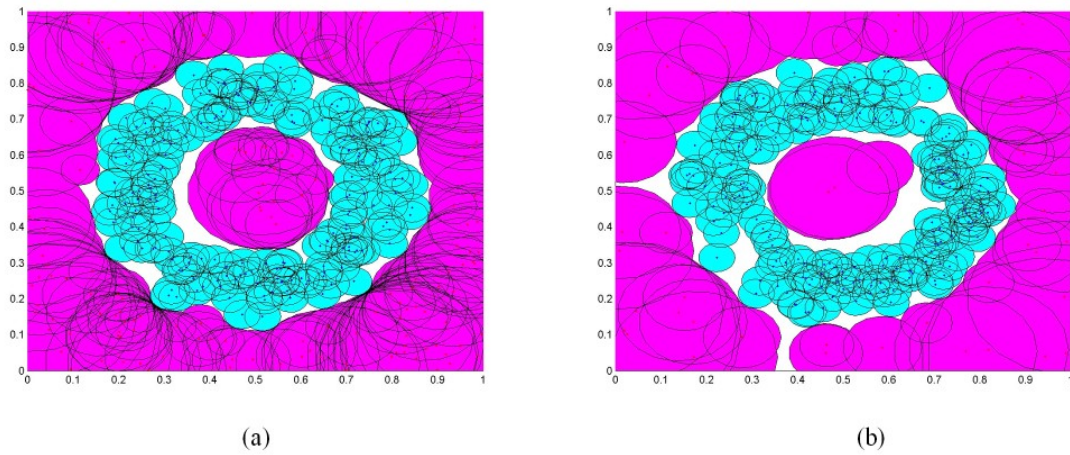


FIGURA 5.8 – Exemplos de resultados com o V-detector com (a) 99% de cobertura estimada e (b) 99,9% de cobertura estimada.

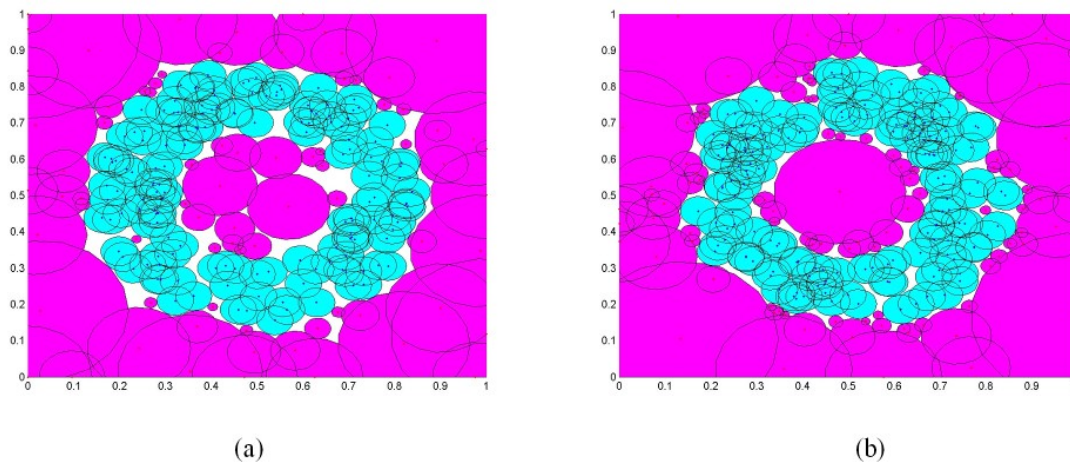


FIGURA 5.9 – Exemplos de resultados com o algoritmo DF-Multioperacional com (a) convergência por número máximo de detectores e (b) por limite de tentativas de alocação de detectores.

5.5.3 Execução dos Experimentos

As simulações de sensibilidade paramétrica previstas foram executados e os resultados médios das execuções são apresentados na Figura 5.10.




FIGURA 5.10 – Análise de desempenho.(a) Cobertura estimada e (b) Taxas de Detecção (%) para o comparativo dos algoritmos estudados.

5.5.4 Discussão e Análise de Resultados

No que diz respeito a cobertura de espaço, para a variação de parâmetros definidas para os experimentos, o algoritmo DF-Multioperacional foi mais eficiente que as implementações usadas para comparação para a massa de dados com uma taxa de detecção média ligeiramente inferior. Desta forma o algoritmo DF-Multioperacional, melhorou a cobertura se comparado aos demais algoritmos. Entretanto, notou-se numa análise preliminar que o tempo de execução dos experimentos para os algoritmos em questão era relativamente alto se comparado a outras técnicas de IC. Esse fato era esperado devido a complexidade computacional desse algoritmo. Entretanto, para a DF esse fato é relevante, uma vez que pode influenciar no tempo de indicação da anomalia e comprometer o algoritmo.

5.6 Aplicação do Algoritmo DF-Multioperacional no *Benchmark* de Sistemas de Acionamentos do Motor de Corrente Contínua

O algoritmo DF-Multioperacional foi executado para a massa de dados do *benchmark* de Sistemas de Acionamentos do Motor de Corrente Contínua (Caminhas, 1997). Os resultados para cada falha (vide Tabela 5.1) apresentam a detecção em 100 conjuntos de detectores e o tempo médio gasto para a detecção da falha, a partir de seu início.

Id	Descrição	Multioperacional	
		<i>dr</i> (%)	<i>td</i> (s)
1	Abertura do Circuito de Armadura	100	0,0060
2	Curto Circuito da Armadura	100	0,0137
3	Abertura do Circuito de Campo	100	0,0040
4	Curto Circuito no Campo	100	0,0645
5	Falha no Sensor de Corrente de Armadura	75	0,0040
6	Falha no Sensor de Corrente de Campo	100	0,0040
7	Falha no Sensor de Velocidade	30	0,0040

TABELA 5.1 – Resultados do algoritmo DF-Multioperacional para o *benchmark* do motor elétrico.

5.6.1 Discussão e Análise de Resultados

O algoritmo DF-Multioperacional possui um custo computacional elevado no treinamento em relação ao algoritmo de raio constante e ao V-detector e consequentemente a outros métodos de detecção de falhas baseados em IC.

No que diz respeito a aplicação do algoritmo DF-Multioperacional no *benchmark* de sistemas de acionamentos do motor de corrente contínua (Caminhas, 1997) as falhas 5 e 7 tiveram uma taxa de detecção menor que as demais. Uma análise mais profunda deve

ser feita para entender o motivo da relativa baixa detecção de falhas, entretanto análises preliminares indicam que a normalização pode ter influenciado neste resultado.

Apesar do algoritmo DF-Multioperacional apresentar uma melhoria na cobertura no espaço de formas real para a codificação real, o desafio referente a complexidade computacional dificulta o uso para detecção de falhas em tempo real.

Como na literatura não foram encontrados dados publicados para comparar individualmente os resultados por tipo de falhas (como foi feito no *benchmark* DAMADICS), foi calculado o índice global de desempenho (igd) do algoritmo de detecção como sendo a média das taxas de detecção individuais. Esse índice foi de $igd = 86,4\%$. Foi encontrado um trabalho na literatura (Caminhas and Takahashi, 2001) que fornece o $igd = 99,3\%$ o que mostra uma diferença média de $12,9\%$ e evidencia que outro método da literatura supera, em termos de índice de desempenho, o algoritmo proposto.

Capítulo 6

Conclusões e perspectivas futuras

“O assunto mais importante do mundo pode ser simplificado até ao ponto em que todos possam apreciá-lo e compreendê-lo. Isso é - ou deveria ser - a mais elevada forma de arte.”

Charles Chaplin

Este capítulo consolida os temas apresentados nesta tese e as propostas de continuidade associada.

6.1 Visão Geral

O foco desta tese - automatização do processo de detecção de falhas - é o passo inicial para a automatização do AEM (“Abnormal Event Management”) usando abordagens imunoinspiradas. Neste contexto, três abordagens propostas foram formalizadas em algoritmos por meio de SIAs para detecção de falhas, a saber:

1. DF-NKC (Detecção de Falhas inspirada nas células *natural killer*) - baseado nos mecanismos de ativação e maturação das células *natural killer* (NK);
2. DF-DM (Detecção de Falhas inspirada no Modelo do Perigo) - baseado no modelo do perigo e no modelo matemático do sistema imune biológico proposto por De Pillis et al. (2005);
3. DF-Multioperacional - baseado em aprimoramentos dos algoritmos de seleção negativa existentes, buscando melhorar a cobertura do espaço não próprio.

De forma macro, a tese consistiu em:

1. Análise de modelos imunes descritos na literatura e definição da metodologia empregada para cada abordagem imunoinspirada proposta para detecção de falhas. No algoritmo DF-NKC a revisão na literatura focou-se nos mecanismos imunes encontrados das células NK. Finalmente, no algoritmo DF-DM a revisão baseou-se no Modelo do Perigo e Modelos Matemáticos do Sistema Imune. No que diz respeito ao algoritmo DF-Multioperacional - focado no modelo de seleção negativa - dois algoritmos existentes na literatura foram descritos, implementados e testados permitindo análise comparativa;
2. Desenvolvimento e implementação de aplicativo para detecção de falhas em sistemas dinâmicos usando bases de dados em modo *off-line*. Foram propostos e implementados os algoritmos DF-Multioperacional, DF-NKC e DF-DM em Matlab para detecção de falhas;
3. Comparação do desempenho do modelo proposto com outros algoritmos - as abordagens propostas foram comparadas com outras abordagens encontradas na literatura.

O detalhamento para cada uma das abordagens proposta nesta tese é apresentado nas seções seguintes, assim como as principais conclusões e propostas de continuidade.

6.2 Proposição: Algoritmo DF-NKC

6.2.1 Resumo da Abordagem

Estruturou-se uma metodologia para detecção de falhas utilizando inspirações dos mecanismos propostos das células NK. Essa abordagem foi denominada de DF-NKC. A abordagem proposta foi aplicada para a detecção de falhas usando o *benchmark* DAMADICS (*Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems*). A proposição foi implementada, validada e comparada a outras metodologias encontradas na literatura. Além disso, foi feita a análise paramétrica do algoritmo e sintonia de parâmetros utilizando DOE (*Design Of Experiments*) e análise de significância estatística.

6.2.2 Conclusões

Obteve-se indicadores de detecção de falhas com índice de desempenho comparável aos demais algoritmos encontrados na literatura (Lemos Paim, 2007; Previdi and Parisini, 2006).

6.2.3 Proposta de Continuidade

- Propõe-se como continuidade a explorar metáforas do sistema imune como um sistema complexo. Desta forma, ao invés de se utilizar unicamente as inspirações das células NK poderia ser explorado a metáfora de interação do sistema imune inato com o adaptativo, permitindo, não somente a detecção da falha, como também seu diagnóstico (Mumford and Jain, 2009);
- Um mecanismo mais elaborado de decisão da população pode ser gerado. Neste caso, a média de citocinas liberada pela população seria utilizada para definir o status de cada célula (ativada ou desativada). Neste contexto, a média de citocinas liberadas pela população alteraria o equilíbrio de cada célula NK (Figura 6.1);

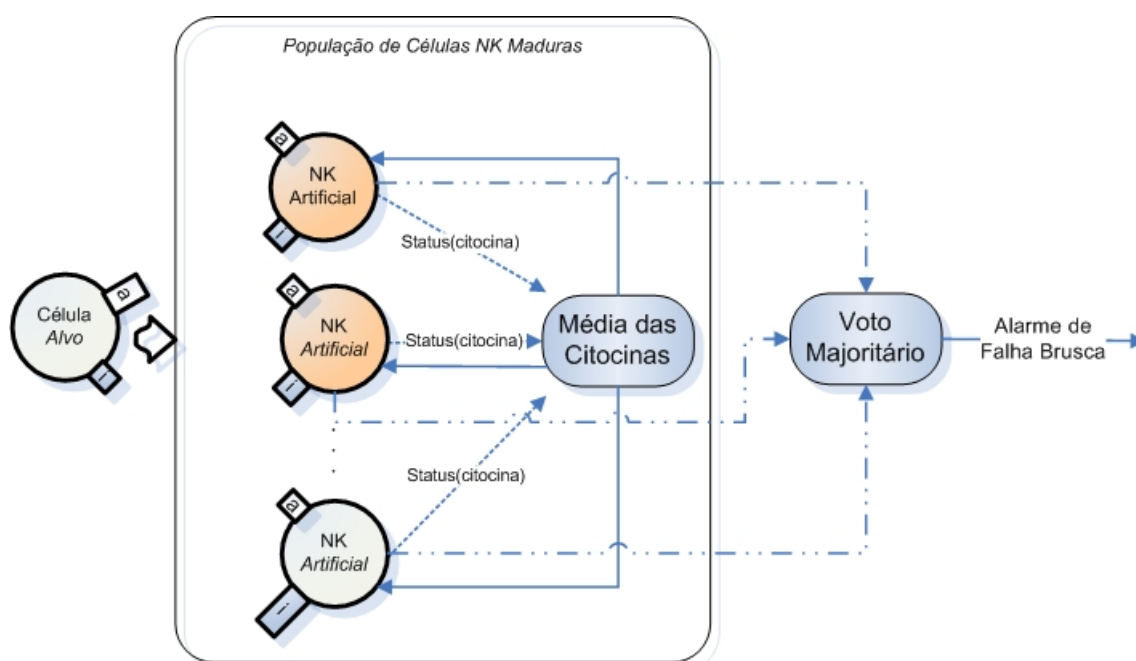


FIGURA 6.1 – Sugestão de continuidade - criação de nova abordagem para interpretar os resultados da detecção inicial gerada pelo algoritmo DF-NKC para permitir detecção de falhas incipientes e diagnóstico de falha.

- A abordagem pode ser utilizada como entrada para um mecanismo de detecção de

falhas incipientes. Neste modelo propõe-se que as citocinas liberadas pela população de células NK artificiais poderia ser utilizado para um mecanismo de detecção de falhas incipientes. Esse mecanismo seria uma analogia entre o sistema imune inato (representado pelas células NK) e o sistema imune adaptativo (Figura 6.2).

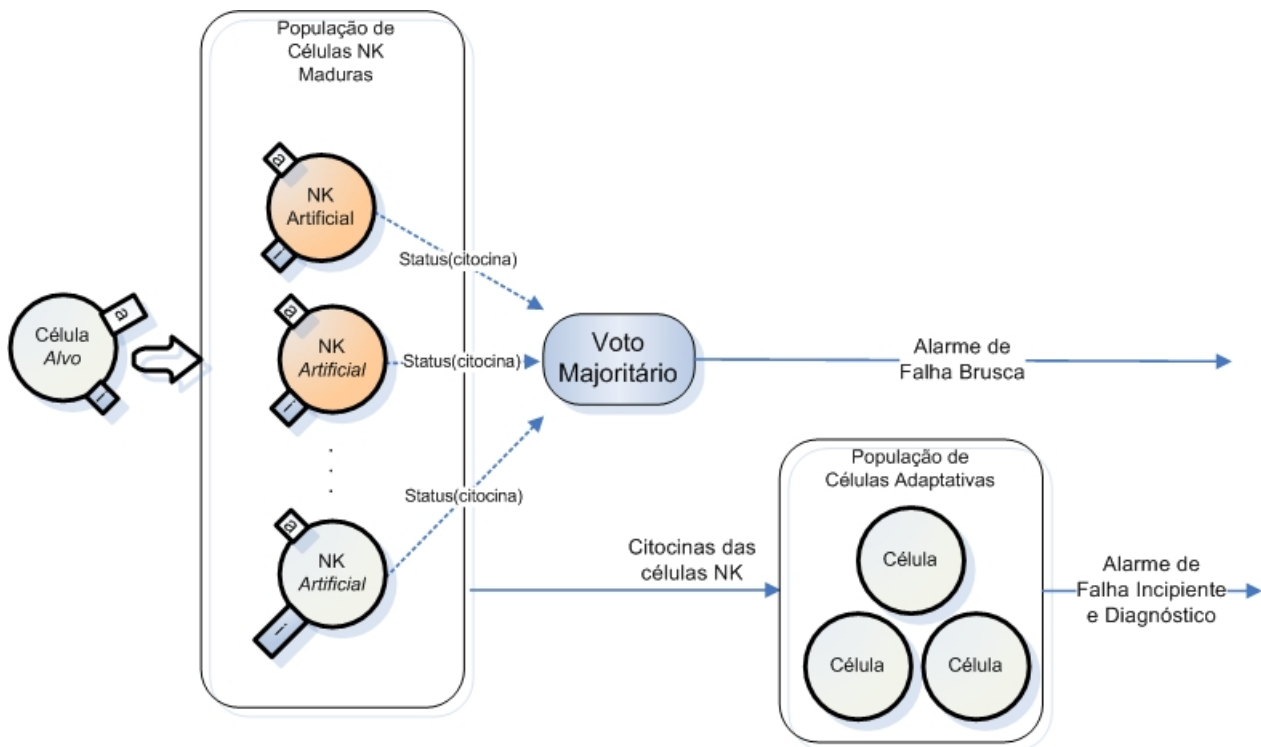


FIGURA 6.2 – Sugestão de continuidade para o DF-NKC - criação de nova abordagem para interpretar os resultados da detecção inicial gerada pelo algoritmo DF-NKC para permitir detecção de falhas incipientes e diagnóstico de falha.

6.3 Proposição: Algoritmo *Danger Model*

6.3.1 Resumo da Abordagem

O algoritmo DF-DM (de Almeida et al., 2010) é inspirado no modelo do perigo proposto por Matzinger (2002) e no modelo matemático da resposta das células NK descrito por De Pillis et al. (2005). A abordagem proposta foi aplicada para a detecção de falhas usando o *benchmark* DAMADICS (Bartys et al., 2006). A proposição foi implementada, validada e comparada a outras metodologias encontradas na literatura com o *benchmark* mencionado.

6.3.2 Conclusões

De maneira geral, o algoritmo DF-DM apresentou resultados relativamente superiores para as taxas de detecção do que os métodos encontrados na literatura aplicados a esse problema (Previdi and Parisini, 2006). Verificou-se ainda que o sistema projetado tem um desempenho ligeiramente superior ao de Lemos Paim (2007) com o custo da possibilidade de alarme falso superior as demais referências encontradas na literatura.

6.3.3 Proposta de Continuidade

- Aplicação de outros modelos matemáticos para implementação do modelo do dano. Alguns candidatos a modelos são descritos pela Tabela 6.1, que mapeiam desde o processo inflamatório (Sullivan and Yotov, 2006) até modelos que descrevem a tuberculose (Wigginton and Kirschner, 2001);

Autor(es)	Modelo Simulado	Metodologia
Sullivan and Yotov (2006)	Modelo Inflamatório	Equações Diferenciais
Hsing (2002)	Modelo de Macrófagos	Redes Semânticas
Wigginton and Kirschner (2001)	Modelo de Ativação de Macrófagos	Equações Diferenciais
De Pillis et al. (2005)	Modelo das Células <i>Natural Killer</i>	Equações Diferenciais
de Almeida and Moreira (2007)	Modelo de Células T	Equações Diferenciais

TABELA 6.1 – Trabalhos encontrados sobre modelagem de Sistemas Imunes que podem ser aplicados como proposta de continuidade ao algoritmo DF-DM

- Uma análise de sensibilidade paramétrica no modelo matemático do sistema proposto é importante para entender o comportamento de variação de desempenho do algoritmo em função dos parâmetros utilizados. Teste preliminares evidenciaram não convergência do modelo, requerendo uma análise mais profunda;
- O sinal de segurança proposto para detecção de falhas pode ser gerado por um conjunto de modelos e não por um único. A analogia com o sistema imune seria que um conjunto de sinais de segurança, onde cada um dos modelos que fornecem

um sinal intermediário, poderiam ser combinados para gerar um senso de segurança mais aprimorado;

- Inclusão de analogias com mecanismos imunoinspirados para redução de alarmes falsos para aperfeiçoar o desempenho do algoritmo de detecção de falhas.

6.4 Proposição: Algoritmo DF-Multioperacional

6.4.1 Resumo da Abordagem

Estudou-se e implementou-se algoritmos baseados no mecanismo de seleção negativa e foi proposto um novo algoritmo: o DF-Multioperacional. Os algoritmos de Raios Constantes, V-Detector e DF-Multioperacional implementados foram aplicados no *benchmark* de Coroa Circular. O algoritmo DF-Multioperacional gerou cobertura mais eficiente com relativamente menos detectores do que os já existentes na literatura para o *benchmark* da Coroa Circular.

O algoritmo DF-Multioperacional foi aplicado ao *benchmark* do sistema de acionamento do motor de corrente contínua (Caminhas, 1997) e os resultados mostraram que o desempenho desse algoritmo para a detecção de falhas foi inferior ao desempenho gerado por Caminhas and Takahashi (2001).

6.4.2 Conclusões

Apesar do algoritmo DF-Multioperacional apresentar uma melhoria na cobertura no espaço de forma real para a Coroa Circular, o desafio referente a complexidade computacional dificulta o uso para detecção de falhas em tempo real.

6.4.3 Proposta de Continuidade

- Deve-se explorar um algoritmo que seja tenha menor tempo computacional especialmente para aplicações em detecção de falhas em tempo real;
- Sugere-se explorar a análise de tempo computacional para os algoritmos de seleção negativa incluindo o DF-Multioperacional;

-
- Sugere-se utilizar um método híbrido de IC para mapear os detectores gerados pelos algoritmos de seleção negativa, buscando uma redução de complexidade computacional, pelo menos para a execução do algoritmo;
 - Sugere-se que para o algoritmo de detecção de raios constantes, os detectores que reconhecem os pontos próprios devam ser armazenados para evitar geração em pontos próximos dessas condições, uma vez que os mesmos são reconhecidamente próprios.

Referências Bibliográficas

- Aguirre, L. A. (2000). *Introdução a Identificação de Sistemas: Técnicas Lineares e Não-lineares aplicadas a sistemas reais*. Editora UFMG. 58
- Amaral, J. L. M. d. (2006). Sistemas imunológicos artificiais aplicados à detecção de falhas. Master's thesis, Pontifícia Universidade Católica do Rio de Janeiro. 24
- Anfossi, N., André, P., Guia, S., Falk, C. S., Roetynck, S., Stewart, C. A., Bresó, V., Frassati, C., Reviron, D., Middleton, D., Romagné, F., Ugolini, S., and Vivier, E. (2006). Human nk cell education by inhibitory receptors for mhc class i. *Immunity*, 25(2):331–342. 29
- Antony, J. (2006). *Design of Experiments for Engineers and Scientists*. Butterworth-Heinemann. 48
- Bagajewicz, M. J. (2009). *Smart Process Plants: Software and Hardware Solutions for Data Accuracy: Data Reconciliation, Gross Error Detection, and Instrumentation Upgrade*. McGraw Hill Professional. 10, 11
- Balachandran, S. (2005). Multi-shaped detector generation using real valued representation for anomaly detection. Master's thesis, Universidade de Memphis. xxi, 24, 81
- Bartys, M., Patton, R., Syfert, M., de las Heras, S., and Quevedo, J. (2006). Introduction to the damadics actuator fdi benchmark study. *Control Engineering Practice*, 14(6):577–596. xvii, 5, 6, 13, 14, 16, 17, 54, 98
- Bezdek, J. C. (1992). On the relationship between neural networks, pattern recognition and intelligence. *Int. J. Approx. Reasoning*, 6(2):85–107. 21

- Brodin, P., Lakshmikanth, T., Johansson, S., Karre, K., and Hoglund, P. (2009). The strength of inhibitory input during education quantitatively tunes the functional responsiveness of individual natural killer cells. *Blood*, 113(11):2434–2441. 30
- Calisto, H., Martins, N., and Afgan, N. (2008). Diagnostic system for boilers and furnaces using cfd and neural networks. *Expert Systems with Applications*, 35(4):1780–1787. 23
- Caminhas, W. and Takahashi, R. (2001). Dynamic system failure detection and diagnosis employing sliding mode observers and fuzzy neural networks. In *IFSA World Congress and 20th NAFIPS International Conference, 2001. Joint 9th*, volume 1, pages 304–309. 6, 19, 93, 100
- Caminhas, W. M. (1997). Estratégias de detecção e diagnóstico de falhas em sistemas dinâmicos. Master’s thesis, Faculdade de Engenharia Elétrica e de Computação - UNICAMP. xvii, 5, 6, 19, 21, 92, 100
- Carayannopoulos, L. N. and Yokoyama, W. M. (2004). Recognition of infected cells by natural killer cells. *Current Opinion in Immunology*, 16(1):26–33. xviii, 33
- Chiang, L., Russell, E., and Braatz, R. (2002). Fault detection and diagnosis in industrial systems. *Journal of Process Control*, 12(3):453 – 454. 11
- Colonna, M. (1998). Immunology: Unmasking the killer’s accomplice. *Nature*, 391(6668):642–643. 32
- D. Dasgupta, K. Krishnakumar, D. W. and Berry, M. (2004). *Negative Selection Algorithm for Aircraft Fault Detection*. Springer Berlin / Heidelberg. 24, 82
- Dai, X., Liu, G., and Long, Z. (2008). Discrete-time robust fault detection observer design: A genetic algorithm approach. In *Intelligent Control and Automation, 2008. WCICA 2008. 7th World Congress on*, pages 2843–2848. 10
- D’Angelo, M. V., Palhares, R. M., Caminhas, W. M., Takahashi, R. H. C., Maia, R. D., and Lemos, A. P. (2010). Detecção de falhas: Uma revisão com aplicações. *Revista Controle e Automação (Submetido)*. 6
- Das, S., Gui, M., and Pahwa, A. (2008). *Studies in Computational Intelligence: Artificial Immune Systems for Self-Nonself Discrimination: Application to Anomaly Detection*. Springer. 62

- Dasgupta, D. (2006). Advances in artificial immune systems. *IEEE Computational Intelligence Magazine*, 6. xvii, 22
- Dasgupta, D. and Forrest, S. (1995). Tool breakage detection in milling operation using a negative selection algorithm. Technical report, Departamento de Ciência da Computação, Faculdade do Novo México. 24
- de Almeida, C. A. L., Bomfim, C. H. M., Caminhas, W. M., and Menezes, B. R. (2005). Building a leakage detector system using ensembles: A new way. *Congresso Brasileiro de Redes Neurais*, 1(1):1–6. 10
- de Almeida, C. L., Braga, A. P., Nascimento, S., Paiva, V., Martins, H., Torres, R., and Caminhas, W. (2009). Intelligent thermographic diagnostic applied to surge arresters: A new approach. *Power Delivery, IEEE Transactions on*, 24(2):751–757. 5, 10
- de Almeida, C. L., Palhares, R. M., and Caminhas, W. M. (2010). Design of an artificial immune system based on danger model for fault detection. *Expert Systems With Application, Elsevier Editorial, DOI:10.1016/j.eswa.2009.12.079*. 6, 98
- de Almeida, M. C. and Moreira, H. N. (2007). A mathematical model of immune response in cutaneous leishmaniasis. *Journal of Biological Systems*, vol. 15. 99
- de Castro, L. and Von Zuben, F. (2002). Learning and optimization using the clonal selection principle. *Evolutionary Computation, IEEE Transactions on*, 6(3):239–251. 23
- de Castro, L. N. (2001). Engenharia imunológica: Desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais. Master's thesis, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas. xxi, 22, 80, 84
- de Castro, L. N. (2006). *Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications*. Chapman and Hall/Crc Computer and Information Sciences. xvii, 5, 21, 22
- de Castro, L. N. and Timmis, J. (2002). *Artificial Immune Systems: A New Computational Intelligence Approach*, volume 4815. Springer, Caterbury / UK. 21, 22

- De Pillis, L. G., Radunskaya, A. E., and Wiseman, C. L. (2005). A validated mathematical model of cell-mediated immune response to tumor growth. *AACRJOURNAL*. xxiv, 25, 61, 63, 64, 74, 75, 95, 98, 99
- Demsar, J. (2006). Statistical comparisons of classifiers over multiple data sets. *J. Mach. Learn. Res.*, 7:1–30. xxiv, 58, 59
- Ding, S. X. (2008). *Model-based Fault Diagnosis Techniques: Design Schemes, Algorithms, and Tools*. Springer. 12
- F. Colucci, J. P. S. and Leibson, P. J. (2002). Natural killer cell activation in mice and men: different triggers for similar weapons? Technical report, Nature Publishing. xviii, 29, 63, 70
- Fangping, M. (2003). Multivariate statistical process monitoring and its integration with hazop analysis for abnormal event management. Master's thesis, Purdue University. 1
- Feng, E., Yang, H., and Rao, M. (1998). Fuzzy expert system for real-time process condition monitoring and incident prevention. *Expert Systems with Applications*, 15(3-4):383–390. 10
- Forrest, S., Perelson, A., Allen, L., and Cherukuri, R. (1994a). Self-nonsel self discrimination in a computer. In *Research in Security and Privacy, 1994. Proceedings., 1994 IEEE Computer Society Symposium on*, pages 202–212. 62
- Forrest, S., Perelson, A., Allen, L., and Cherukuri, R. (1994b). Self-nonsel self discrimination in a computer. In *Research in Security and Privacy, 1994. Proceedings., 1994 IEEE Computer Society Symposium on*, pages 202–212. 80, 81
- Fulcher, J. and Jain, L. C. (2008). *Computational Intelligence: A Compendium*. Springer. 21
- Gan, Z., Zhao, M.-B., and Chow, T. W. S. (2009). Induction machine fault detection using clone selection programming. *Expert Systems with Applications*, 36(4):8000–8012. 23
- García, S., Molina, D., Lozano, M., and Herrera, F. (2008). A study on the use of non-parametric tests for analyzing the evolutionary algorithms' behaviour: A case study on the cec' 2005 special session on real parameter optimization. *Journal of Heuristics*. 58

- Gayaka, S., Yao, B., and Meckl, P. (2007). Fault detection for nonlinear systems in presence of input unmodeled dynamics. In *Advanced intelligent mechatronics, 2007 iee/asme international conference on*, pages 1–5. 10
- Gonzalez, F. A. and Dasgupta, D. (2004). Anomaly detection using real-valued negative selection. In *Journal of Genetic Programming and Evolvable Machines*, pages 4–383. 23
- González, F. (2003). A study of artificial immune systems applied to anomaly detection. Master’s thesis, Universidade de Memphis. 24
- González, F. A. and Dasgupta, D. (2004). Anomaly detection using real-valued negative selection. *Genetic Programming and Evolvable Machines*, 4(4):383–403. 83
- Greensmith, J., Aickelin, U., and Cayzer, S. (2005). *Introducing Dendritic Cells as a Novel Immune-Inspired Algorithm for Anomaly Detection*, chapter Introducing Dendritic Cells as a Novel Immune-Inspired Algorithm for Anomaly Detection, pages 153–167. ICARIS, 4th International Conference on Artificial Immune Systems. 23
- Guzella, T. S., Mota-Santos, T. A., and Caminhas, W. M. (2007). A novel immune inspired approach to fault detection. *Lecture Notes in Computer Science*, pages 107–118. 23
- Helmy, A., Holdmann, M., and Rizkalla, M. (2008). Application of thermography for non-invasive diagnosis of thyroid gland disease. *Biomedical Engineering, IEEE Transactions on*, 55(3):1168–1175. 10
- Hsing, M. (2002). Modeling of cell signaling pathways in macrophages by semantic networks. Master’s thesis, Simon Fraser University. 99
- Ishida, Y. and Mizessyn, F., editors (1992). *Learning Algorithms on an Immune Network Model: Application to Sensor Diagnosis. Proceedings of International Joint Conference on Neural Networks*. 23
- Ji, Z. (2006). Negative selection algorithms: From the thymus to v-detector. Master’s thesis, University of Memphis. 6, 24, 85
- Ji, Z. and Dasgupta, D. (2004). Augmented negative selection algorithm with variable-coverage detectors. *Congress on Evolutionary Computation*, 1(1):1081–1088. 83

- Ji, Z. and Dasgupta, D. (2005). Estimating the detector coverage in a negative selection algorithm. In *Proceedings of the 2005 conference on Genetic and evolutionary computation, Genetic And Evolutionary Computation Conference*, pages 281–288, Washington DC, USA. 6
- Jian, C., Qing-hua, Z., Bu-gong, X., Ting-yu, G., and Hong-fang, L. (2009). Application research for fault diagnosis of machine unit based on immunology principle. In *Networks Security, Wireless Communications and Trusted Computing, 2009. NSWCTC '09. International Conference on*, volume 2, pages 776–779. 24
- Johansson, M. H. and Höglund, P. (2006). The dynamics of natural killer cell tolerance. *Seminars in Cancer Biology*, 16(5):393–403. 28, 29, 31
- Johansson, S., Divon, M. S., Johansson, M. H., Pickman, Y., Brodin, P., Karre, K., Mehr, R., and Höglund, P. (2009). Probing natural killer cell education by ly49 receptor expression analysis and computational modelling in single mhc class i mice. *PLoS ONE*, 4(6). 31
- Johansson, S., Johansson, M., Rosmaraki, E., Vahlne, G., Mehr, R., Salmon-Divon, M., Lemonnier, F., Karre, K., and Höglund, P. (2005). Natural killer cell education in mice with single or multiple major histocompatibility complex class I molecules. *Journal Experimental Medicine*, 201(7):1145–1155. 30, 31
- Kightley, R. (2009). Ilustração de uma célula nk. <http://www.rkm.com.au/IMMUNOLOGY/Killer-Cell.html>. xviii, 28
- Kim, J. and Bentley, P. J. (2002). Towards an artificial immune system for network intrusion detection: An investigation of dynamic clonal selection. *Congress on Evolutionary Computation*, pages 1015 – 1020. 23
- Kleijnen, J. (2008). Design of experiments: Overview. In *Simulation Conference, 2008. WSC 2008. Winter*, pages 479–488. 48
- Kurilenko, G. (2004). Using of thermography approach for nondestructive check up in industry. In *Science and Technology, 2004. KORUS 2004. Proceedings. The 8th Russian-Korean International Symposium on*, volume 3, pages 32–34. 10

- L. Fang, Q. B. and Rongsheng, C. (2004). *Intrusion Detection Based on Immune Clonal Selection Algorithms*. Springer Berlin, pg 1226-1232. 23
- Lanier, L. L. (2008). Up on the tightrope: natural killer cell activation and inhibition. *Nature Immunology*, 9(5):495–502. 6, 28
- Lemos Paim, A. P. (2007). Proposta de um algoritmo genérico de detecção de novidades em séries temporais utilizando modelos de previsão. Master's thesis, Universidade Federal de Minas Gerais. 6, 57, 58, 59, 76, 77, 97, 99
- Ligang, W. and Daniel, H., editors (2009). *Fuzzy Filter Design for Itô Stochastic Systems With Application to Sensor Fault Detection*. *Fuzzy Systems, IEEE Transactions on*. 5
- López-Larrea, C., Suárez-Alvarez, B., López-Soto, A., López-Vázquez, A., and Gonzalez, S. (2008). The nkg2d receptor: sensing stressed cells. *Trends in Molecular Medicine*, 14(4):179–189. 28, 32
- Lu, K.-Y. and Sy, C.-C. (2009). A real-time decision-making of maintenance using fuzzy agent. *Expert Systems with Applications*, 36(2, Part 2):2691–2698. 10
- Luci, C., Reynders, A., Ivanov, I. I., Cognet, C., Chiche, L., Chasson, L., Hardwigsen, J., Anguiano, E., Banchereau, J., Chaussabel, D., Dalod, M., Littman, D. R., Vivier, E., and Tomasello, E. (2009). Influence of the transcription factor ror[gamma]t on the development of nkp46+ cell populations in gut and skin. *Nat Immunol*, 10(1):75–82. 28
- Luci, C. and Tomasello, E. (2008). Natural killer cells: Detectors of stress. *The International Journal of Biochemistry and Cell Biology*, 40(11):2335–2340. 28
- Luo, M., Zhang, D. H., Zhao, Y. Z., and Zhang, J. B. (2004). A structured methodology for the development of anticipative event management systems with self-recovery capability. In *Industrial Electronics Society, 2004. IECON 2004. 30th Annual Conference of IEEE*, volume 3, pages 2614–2619. 1
- Matzinger, P. (2001). The danger model in its historical context. *Scandinavian Journal of Immunology*, vol. 54. 62
- Matzinger, P. (2002). The danger model: A renewed sense of self. *Science Magazine*, vol. 296. xx, 6, 61, 62, 63, 65, 98

- Mendonça, L. F., Sousa, J. M. C., and Sá da Costa, J. M. G. (2009). An architecture for fault detection and isolation based on fuzzy methods. *Expert Systems with Applications*, 36(2, Part 1):1092–1104. 10
- Ministério da Previdência Social (MPS) (Acessado em: 20 de maio de 2009). Estatísticas de acidentes de trabalho. <http://creme.dataprev.gov.br/AEAT/GLiq/Liq01/Liq01.htm>. xvii, 2, 3
- Moretta, L. (2007). Nk cell-mediated immune response against cancer. *Surgical Oncology*, 16(Supplement 1):3–5. 28, 33
- Mumford, C. L. and Jain, L. C. (2009). *Computational Intelligence: Collaboration, Fusion and Emergence*. Springer. 97
- Neal, M. (2003). *Meta-stable Memory in an Artificial Immune Network*, chapter Meta-stable Memory in an Artificial Immune Network, pages 168–180. Springer. 23
- Previdi, F. and Parisini, T. (2006). Model-free actuator fault detection using a spectral estimation approach: the case of the damadics benchmark problem. *Control Engineering Practice*, 14(6):635–644. 6, 18, 57, 58, 59, 76, 97, 99
- Rajshekhhar, Gupta, A., Samanta, A., Kulkarni, B., and Jayaraman, V. (2007). *Fault Diagnosis Using Dynamic Time Warping*, volume 4815. Springer, Berlin / Heidelberg. 1
- Raulet, D. H., Vance, R. E., and McMahon, C. W. (2001). Regulation of the natural killer cell receptor repertoire. *ANNUAL REVIEW OF IMMUNOLOGY*, 19:291–330. xviii, 29, 30, 31
- Ren, W. and Wang, Q. (2008). A new negative selection algorithm and its application in the fault diagnosis of the pump-jack. In *Intelligent Control and Automation, 2008. WCICA 2008. 7th World Congress on*, pages 1945–1950. 24
- Ronacher, G., de Almeida, C. L., and Caminhas, W. M. (2006). Detecção de falhas em sistemas dinâmicos utilizando princípios imunológicos. *XVI Congresso Brasileiro de Automática*. 6
- S. Simani, C. F. and Patton, R. (2003). *Model-Based Fault Diagnosis In Dynamic Systems Using Identification Techniques*. Springer. 12

- Silva, C. W. D. (2007). *Vibration monitoring, testing, and instrumentation*. CRC Press. 10
- Sullivan, J. and Yotov, I. (2006). Mathematical and numerical modeling of inflammation. *University of Dayton, Ohio*. 99
- Taylor, J. and Sayda, A. (2005). An intelligent architecture for integrated control and asset management for industrial processes. In *Intelligent Control, 2005. Proceedings of the 2005 IEEE International Symposium on, Mediterrean Conference on Control and Automation*, pages 1397–1404. 1
- Timmis, J., Andrews, P., Owens, N., and Clark, E. (2008a). An interdisciplinary perspective on artificial immune systems. *Evolutionary Intelligence*, 1(1):5–26. 21
- Timmis, J., Hart, E., M., H. A. N., Robins A., S. S., and A., T. (2008b). Immuno-engineering. *2nd IFIP International Conference on Biologically Inspired Collaborative Computing, 20th IFIP World Computer Congress, Milan, Italy*, 268(200):3–18. 21
- Uyar, M., Yildirim, S., and Gencoglu, M. T. (2009). An expert system based on s-transform and neural network for automatic classification of power quality disturbances. *Expert Systems with Applications*, 36(3, Part 2):5962–5975. 23
- Venkatasubramanian, V., Rengaswamy, R., Yin, K., and Kavuri, S. (2003). A review of process fault detection and diagnosis - part i: Quantitative model-based methods. *Computers and Chemical Engineering*, 27:293–311(19). 2, 10
- Vivier, E. (2006). What is natural in natural killer cells? *Immunology Letters*, 107(1):1–7. xviii, 31, 32
- Vivier, E., Nunes, J. A., and Vely, F. (2004). Natural killer cell signaling pathways. *Science*, 306(5701):1517–1519. 28
- Vivier, E., Tomasello, E., Baratin, M., Walzer, T., and Ugolini, S. (2008). Functions of natural killer cells. *Nature Immunology*, 9(5):503–510. 6
- Wan, K. and Ma, Q. (2009). Data-fitting reconstruction for defect inspection of airplane aluminum structure in infrared thermographic ndt. In *Industrial Electronics and Applications, 2009. ICIEA 2009. 4th IEEE Conference on*, pages 691–696. 10

- White, D. C. (2003). Creating the smart plant. *Hydrocarbon Processing*, pages 41–50. 10
- Wigginton, J. and Kirschner, D. (2001). A model to predict cell mediated immune regulatory mechanisms during human infection with mycobacterium tuberculosis. *Journal of Immunology*. 99
- Yokoyama, W. M., Kim, S. J., and French, A. R. (2004). The dynamic life of natural killer cells. *ANNUAL REVIEW OF IMMUNOLOGY*, 22:405–429. 29
- Zeng, J., Li, T., Liu, X., Liu, C., Peng, L., and Sun, F. (2007). A feedback negative selection algorithm to anomaly detection. In *Natural Computation, 2007. ICNC 2007. Third International Conference on*, volume 3, pages 604–608. 24
- Zhaoxiang, Y., Xiaodong, M., Li, Z., and Peng, Z. (2008). A matrix negative selection algorithm for anomaly detection. In *Evolutionary Computation, 2008. CEC 2008. (IEEE World Congress on Computational Intelligence). IEEE Congress on*, pages 978–983. 24
- Zidani, F., Diallo, D., El Hachemi Benbouzid, M., and Nait-Said, R. (2008). A fuzzy-based approach for the diagnosis of fault modes in a voltage-fed pwm inverter induction motor drive. *Industrial Electronics, IEEE Transactions on*, 55(2):586–593. 5