

Detecção de falhas em sistemas dinâmicos: Abordagens imunoinspiradas baseadas no reconhecimento antigênico nebuloso

Guilherme Costa Silva¹, Marcos F. S. V. D'ângelo², and
Walmir M. Caminhas³

¹ Programa de Pós Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais, Av. Antônio Carlos, 6627 31270-901, Belo Horizonte, MG, Brazil
`guicosta@ufmg.br`

² Departamento de Ciência da Computação - Universidade Estadual de Montes Claros, Av. Rui Braga, sn, Vila Mauricéia, 39401-089 Montes Claros, Brazil
`marcos.dangelo@unimontes.br`

³ Departamento de Engenharia Eletrônica - Universidade Federal de Minas Gerais, Av. Antônio Carlos, 6627 31270-901, Belo Horizonte, MG, Brazil
`caminhas@cpdee.ufmg.br`

Abstract. Este trabalho apresenta um aperfeiçoamento do modelo nebuloso do reconhecimento antigênico inspirado no sistema imune que será testado através de seu emprego em três tipos de algoritmos imunoinspirados. Os algoritmos estudados são aplicados a problemas de detecção de falhas em sistemas dinâmicos provendo resultados interessantes na detecção das falhas estudadas nos estudos de casos apresentados.

Keywords: Sistemas Imunoinspirados, Reconhecimento Antigênico Nebuloso, Detecção de Falhas

1 Introdução

Os sistemas imunoinspirados são abordagens que têm como inspiração alguns mecanismos, teorias e modelos conhecidos do sistema imune biológico, e utiliza seus princípios na modelagem de sistemas capazes de resolver problemas computacionalmente complexos. Tais abordagens, conforme [1], são parte de uma linha de pesquisa que tem sido bastante consolidada.

Tais sistemas podem ser aplicados em problemas de otimização, agrupamento, classificação e reconhecimento de padrões [2] e, principalmente, detecção de anomalias. Esta última aplicação é bastante estudada uma vez que existem muitos modelos que explicam a resposta imune, como o modelo do Nonselself Infeccioso em [4] e o modelo do Perigo ou Dano em [5].

O principal modelo que explica a resposta imune é baseado nos princípios da discriminação de padrões considerados próprios do organismo (*Self-nonselself*), e tais princípios inspiraram os primeiros tipos de algoritmos imunoinspirados existentes na literatura, utilizados até então desde os trabalhos em [3].

A seleção negativa é intuitivamente relacionada com o desenvolvimento de algoritmos supervisionados de aprendizado de máquina e o reconhecimento de antígenos possui características nebulosas consideradas no modelo em [8]. Este modelo é apenas uma das muitas inspirações que o sistema imune pode prover para a solução eficiente de problemas de engenharia.

O presente trabalho revisita o método do reconhecimento antigênico nebuloso, aplicando o método na implementação de outras duas diferentes abordagens que são inspiradas em um dos modelos recorrentes na imunologia, a serem aplicadas em diferentes estudos de casos de detecção de falhas em sistemas dinâmicos.

A seção 2 apresenta as principais inspirações para as abordagens estudadas no trabalho, em seguida, a seção 3 apresenta os algoritmos estudados e aprimorados, a seção 4 apresenta os estudos de casos de detecção de falhas em sistemas dinâmicos, com os resultados apresentados na seção 5. Finalmente a seção 6 apresenta as conclusões e propostas de continuidade.

2 Inspirações na Resposta Imune

O princípio da discriminação *Self-nonsel* é um dos principais fundamentos no qual o sistema imune biológico foi descrito. Tal princípio inspirou a criação de diversos sistemas computacionais aplicados a problemas de detecção de anomalias, conforme [6].

O reconhecimento antigênico, de acordo com as descrições de [8], possui natureza nebulosa relacionada com a geração de clones sub-ótimos de células T, que ocorre conforme sua afinidade intermediária em relação a padrões próprios do organismo, ilustrada na Figura 1, que ilustra os processos de seleção negativa e positiva, relacionando-os com o modelo nebuloso de resposta imune.

Em [9], dois métodos foram propostos: um deles aperfeiçoa a geração de detectores pelos algoritmos baseados na seleção negativa, o outro detecta anomalias de forma similar ao k-NN, através da distância entre os dados de treinamento e os dados de teste.

Ambos os métodos requerem dados de treinamento para realizar a detecção, o que define os algoritmos baseados na seleção negativa, análoga à maturação das células T. Diferentemente de alguns métodos de classificação, o treinamento destes algoritmos requer apenas dados normais, a anomalia é detectada com base no processamento nebuloso realizado pelo sistema de reconhecimento antigênico que se baseia na métrica de distância, usada para o cálculo da função de avides do sistema.

O modelo nebuloso do reconhecimento antigênico pode ser também uma forma alternativa de prover a classificação de padrões baseada em ensemble, conforme visto em [10].

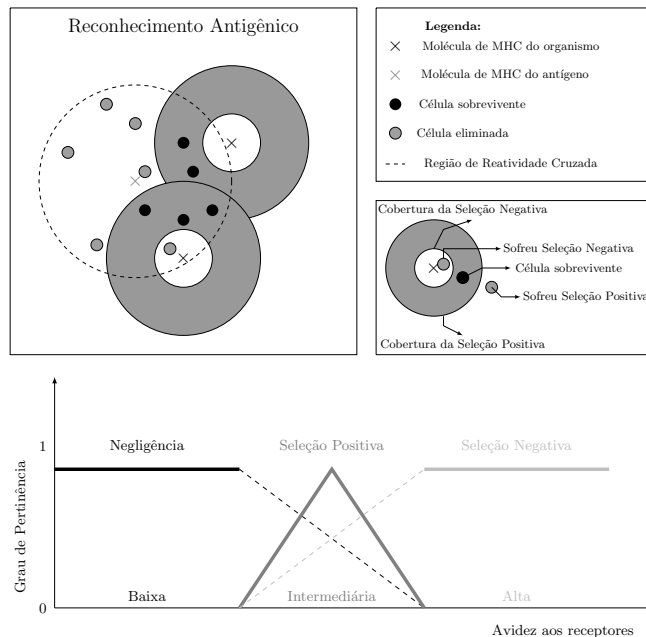


Fig. 1. O Reconhecimento antigênico e sua modelagem nebulosa, conforme [7] e [8].

3 Algoritmos inspirados na resposta imune

São definidos quatro modelos de resposta imune, estes modelos são descritos conforme os sinais requeridos para a ativação da resposta imune. Em cada modelo, o antígeno possui representações diferentes, além da quantidade e tipos de sinais definidos em cada modelo, que inspira diferentes abordagens descritas a seguir.

O primeiro modelo, baseado no princípio da discriminação *self-nonself*, descreve a utilização apenas do antígeno e inspira algoritmos que seguem o modelo de aprendizado supervisionado implícito pelos processos de seleção negativa e positiva.

Os modelos coestimulatórios incluem uma célula apresentadora de antígenos e um sinal coestimulatório que garante a sobrevivência das células envolvidas na resposta imune. Tais modelos inspiram abordagens multiagentes ou que utilizam mais de um tipo de detector. Alternativamente, o modelo do nonself infeccioso estende este modelo, definindo um padrão molecular análogo a evidências de anomalias em sistemas computacionais.

Já o modelo do perigo define a existência de sinais de danos que podem ativar a resposta imune. Os sistemas imunoinspirados baseados neste modelo possuem uma representação mais específica dos sinais indicadores de normalidade ou de anomalias e geralmente dispensam a etapa de aprendizado.

Três abordagens serão estudadas neste trabalho: o método inspirado no reconhecimento antigênico nebuloso para monitoramento e as duas abordagens

inspiradas no modelo do *nonself* infeccioso: o algoritmo de reconhecimento do padrão próprio conservado (CSPRA), e o algoritmo estruturado dos receptores toll-like (STLR). Estas serão aplicadas a problemas de detecção de falhas em sistemas dinâmicos. A escolha destes métodos se deve às características providas por estes métodos e aos poucos estudos realizados com os mesmos.

3.1 Reconhecimento Antigênico Nebuloso

O Reconhecimento Antigênico Nebuloso pode ser utilizado de duas formas conforme definição em [9]: ou para otimizar a geração dos detectores pelos algoritmos baseados na seleção negativa (Método I) ou em uma forma similar ao método k-NN para $k = 1$, que consiste em usar uma métrica de distância e os próprios dados de treinamento para monitorar os dados de teste, simplificando a abordagem baseada na seleção negativa (Método II).

Tanto a abordagem de geração de detectores quanto a abordagem baseada em similaridades são ilustradas na Figura 2, conforme o comportamento dos dados envolvidos durante as etapas de treinamento (geração de detectores) e de teste (monitoramento dos dados), dada uma função de avidez, considerada em (1).

$$\zeta_{Ag_k} = 1 - \frac{Dist(Ag_k, Tr_{min})^h}{1 + Dist(Ag_k, Tr_{min})^h} \quad (1)$$

onde $Dist(Ag_k, Tr_{min})$ é qualquer métrica de distância apropriada para o problema, normalmente a distância Euclideana, definida entre o antígeno Ag_k e dado de treinamento mais próximo Tr_{min} , e h é um fator de potência da função. Nos testes realizados neste trabalho, é considerado $h = 2$.

Tais métodos podem prover a detecção de anomalias de maneiras distintas, sendo inclusive possível incorporá-los a outros métodos imunoinspirados que envolvam o uso de dados de treinamento, como os dois métodos vistos a seguir: o Algoritmo de reconhecimento do padrão próprio conservado, e o Algoritmo de reconhecimento de receptores Toll-like, apresentados a seguir.

3.2 Algoritmo de reconhecimento do padrão próprio conservado

O algoritmo de reconhecimento do padrão próprio conservado (ou CSPRA - *Conserved Self Pattern Recognition Algorithm*), proposto em [11], é um método imunoinspirado que não só serve como uma extensão do algoritmo clássico de seleção negativa, como também é inspirado no modelo do *nonself* infeccioso, contendo analogias com receptores de reconhecimento de padrões (PRR), e contém também inspirações no conceito do próprio alterado (*Altered Self*), descrito em [12] como uma restrição que permite às células T cells o reconhecimento de moléculas MHC do corpo que podem ter sido alteradas em de alguma forma por infecções ou antígenos.

O CSPRA é um algoritmo de monitoramento que considera analogias às células apresentadoras de antígenos (APCs) em detectores alternativos e complementares aos detectores baseados nos receptores das células T. Diferente das

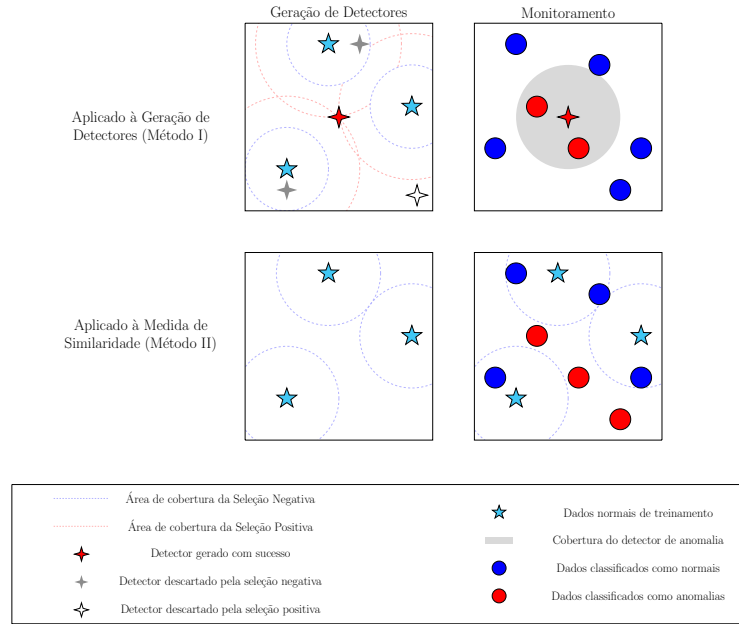


Fig. 2. Ilustração dos algoritmos baseados no reconhecimento antigênico nebuloso.

APCs biológicas, os detectores gerados auxiliam na detecção sem necessariamente impedir que o detector baseado nas células T faça a detecção.

Além da afinidade com os detectores gerados na seleção negativa, outros três critérios são definidos: alta afinidade a um antígeno suspeito, definição de um determinante antigênico para o “Próprio Conservado” no qual o antígeno estaria localizado, e a afinidade com o detector APC. A Figura 3 ilustra o funcionamento do CSPRA com base nestas descrições.

A função de afinidade às células T corresponde ao mesmo processo feito nos algoritmos baseados na seleção negativa, onde a distância entre um padrão antigênico e um detector determina a afinidade e conseqüente detecção de uma anomalia. Além desta função, um limiar adicional, indicativo de antígenos suspeitos é utilizado para classificação.

Já o cálculo da função de afinidade às APCs em relação aos antígenos pode ser definido conforme (2), como uma função de afinidade.

$$APC(Ag) = \sum_{i=1}^d \frac{|Ag_i - Ag_{mn}|}{Ag_{lw} - Ag_{up}} \quad (2)$$

onde d corresponde ao número de dimensões, Ag_{lw} e Ag_{up} são os limites inferior e superior do i -ésimo atributo nos dados de treino, Ag_i é o i -ésimo atributo avaliado e Ag_{mn} é o valor médio do i -ésimo atributo nos dados de treino. Este

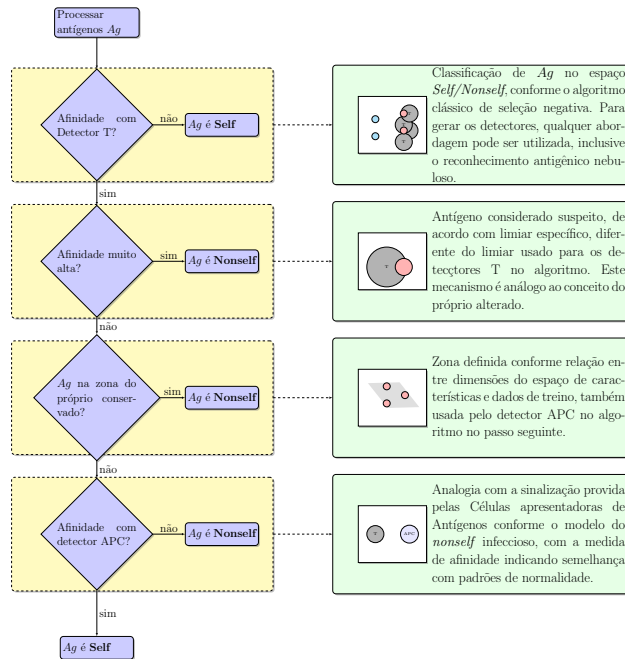


Fig. 3. Fluxograma do CSPRA, com descrição de seus principais passos.

detector também define uma área denominada Zona do Próprio Conservado, onde os dados normais devem estar localizados.

O algoritmo também foi avaliado em [13] no estudo de diferentes bases de dados e em comparação com outros métodos de detecção de anomalias. Desta forma, duas variantes do algoritmo foram testadas: a versão clássica, descrita anteriormente, e a versão seletiva, que utiliza uma estratégia de detecção baseada em votação, com um mecanismo de ambiguidades tratado por ambos os detectores, quando necessário.

Em [14], o algoritmo foi redefinido e aplicado como um sistema de detecção de intrusões em redes de computadores, utilizando de mecanismos semideterminísticos para gerar os detectores. No lugar do limiar usado pelo detector APC, esta variação utiliza dois limiares, ambos com base no modelo do *nonself* infeccioso delimitando as fronteiras entre os espaços *self* e *nonself*.

Neste trabalho, o CSPRA será usado como um método de detecção de falhas em sistemas dinâmicos, com o reconhecimento antigênico nebuloso para ser usado como detector baseado nas células T. Uma vez que o algoritmo é similar à etapa de monitoramento de abordagens clássicas baseadas na seleção negativa, seu desempenho será comparado com o algoritmo clássico.

3.3 Algoritmo de receptores toll-like

O algoritmo dos receptores toll-like (TLRA), proposto em [15], é inspirado em um modelo imune definido em [16], e se baseia na interação entre dois agentes: APCs, que são expostas a estímulos análogos aos PAMPs, e as células T representadas pelos padrões de anomalias processados.

O algoritmo consiste no treinamento de ambos os agentes, sendo que no caso das APCs, os dados representados pelos sinais são armazenados como regras que definem os sinais não processados durante a etapa de treinamento.

A etapa de teste consiste na detecção de sinais não processados. Estes causam a maturação completa das APCs. Caso a célula não processe tais sinais, esta sofre uma semimaturação após alguns ciclos do algoritmo. As células que sofreram maturação interagem com as células T, que no caso de terem detectado um antígeno não processado, ativam a célula T, classificando o dado como anomalia. Caso não ocorra nenhuma das detecções, o dado é classificado como normal.

O algoritmo foi revisto em [17], com algumas alterações propostas, como por exemplo a classificação do espaço nonself representando a ativação das células T no modelo.

Desta forma, a modelagem das células T passou a ser similar à dos algoritmos baseados na seleção negativa, com a ativação condicionada à maturação das APCs com base nas regras definidas durante a etapa de treinamento. Esta variação do algoritmo é denominada Algoritmo estrutural dos receptores toll-like (STLR - *Structural Toll-like Receptor Algorithm* ou STLRA), cujos passos estão ilustrados no fluxograma da Figura 4.

Basicamente, a principal diferença entre o TLRA e o CSPRA está na representação das APCs e no mecanismo de detecção proposto. No TLRA as APCs são representadas pelos agentes que estão expostos aos sinais e o CSPRA possui apenas o sinal que determina a detecção. Este sinal possui conotações diferentes, no caso do TLRA, o sinal determina se a detecção ocorrerá enquanto que o CSPRA, este sinal pode atuar também como um detector auxiliar, determinando o status do sistema.

Neste trabalho, será usada a versão estrutural do algoritmo, que permite a modelagem do espaço *self-nonsel*f através de qualquer detector de anomalias. Da mesma forma que o CSPRA, o STLRA será usado com o reconhecimento antigênico nebuloso em testes de benchmark de detecção de falhas em sistemas dinâmicos.

4 Detecção de Falhas em Sistemas Dinâmicos

Neste trabalho, os métodos apresentados são aplicados aos seguintes problemas de benchmark de detecção de falhas em sistemas dinâmicos descritos a seguir:

- Simulação de falhas incipientes em motores de corrente contínua [9, 18];
- Simulação de curtos circuitos em motores de indução [19, 20];

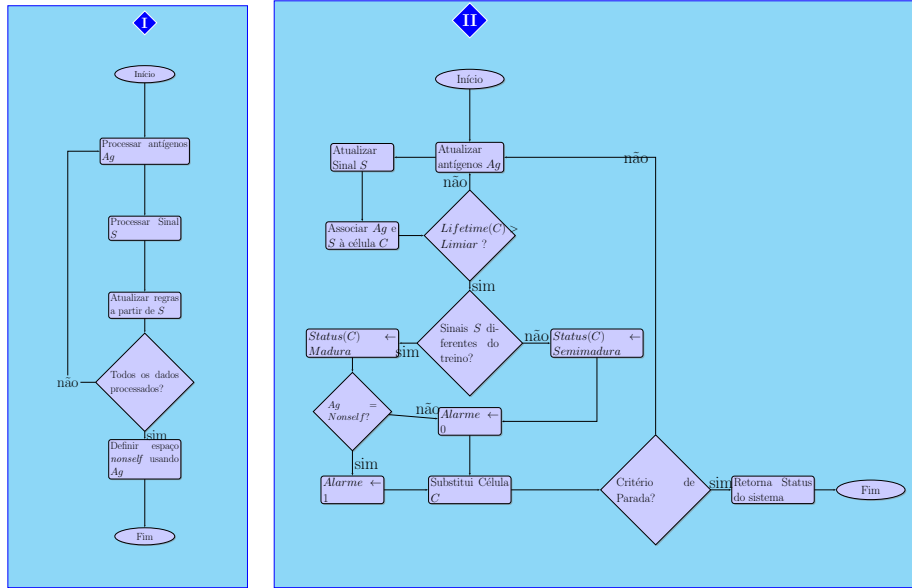


Fig. 4. Fluxograma do STLRA nas etapas de treinamento (I) e teste (II).

Os problemas foram escolhidos pelo fato de haver poucas simulações de detecção de falhas existentes e serem falhas consideradas mais difíceis de serem detectadas, exceto no caso do motor de indução, que já possui alguns resultados. Espera-se que os algoritmos apresentados neste trabalho consigam detectar as falhas a serem apresentadas na Tabela 1.

Table 1. Falhas a serem simuladas e suas respectivas descrições.

ID	Benchmark	Descrição
1	Motor de Corrente Contínua	Falha no sistema de ventilação
2	Motor de Corrente Contínua	Falha de lubrificação dos mancais
3	Motor de Indução	Curto circuito no enrolamento do estator

As simulações foram realizadas considerando um tempo de simulação aleatório de 4, 6, 8 ou 10 segundos, com o instante da falha aleatório, e parâmetros relativos à intensidade ou amplitude das falhas aleatórios. Cada teste foi simulado 100 vezes. Os parâmetros utilizados para as simulações do motor de corrente contínua e de indução podem ser encontrados respectivamente em [18] e [19].

Os algoritmos escolhidos no trabalho são descritos na Tabela 2, conforme a abordagem e a variação definida. No caso do CSPRA, as variações 3 e 4 são consideradas respectivamente em [13] e [14]. Já no caso do TLR, em 5 é considerado o uso do resíduo calculado através de um observador linear para representar os

sinais nos testes 1 e 2, e em 6 a estratégia adotada é a mesma do CSPRA, usando a Equação (2) para representar o sinal, todos os algoritmos usam o reconhecimento antigênico nebuloso para modelar o espaço *nonsel* avaliado.

Table 2. Algoritmos usados nas simulações de detecção de falhas.

ID	Sigla	Descrição
1	FARec	Reconhecimento Antigênico Nebuloso
2	CSPRA-C	Algoritmo de reconhecimento do padrão próprio conservado clássico
3	CSPRA-S	Algoritmo de reconhecimento do padrão próprio conservado seletivo
4	CSPRA-ID	Algoritmo de reconhecimento do padrão próprio conservado para intrusão
5	STLRA-1	Algoritmo estrutural dos Receptores Toll-Like + Estratégia 1
6	STLRA-2	Algoritmo estrutural dos Receptores Toll-Like + Estratégia 2

Os parâmetros de cada algoritmo são listados de acordo com as seguintes definições: para o reconhecimento antigênico nebuloso, usa-se um limiar $T_1 = 0.95$ para definir a região *nonsel* avaliada no sistema nebuloso de inferência. Para o CSPRA (2 a 4), os parâmetros são os especificados na Tabela 3, e para o TLRA (5 e 6), os parâmetros são os especificados na Tabela 4. Vale ressaltar que no algoritmo 6 foi necessário adotar um limiar diferente para o teste 3, devido à baixa taxa de detecção com o limiar usado para os demais testes.

Table 3. Parâmetros usados pelo CSPRA e suas variações.

Variável	Descrição	Valor usado	Algoritmos
T_2	Limiar de detecção usado pelo detector APC	1	2 e 3
T_3	Limiar que determina se um antígeno é suspeito	0.02	2
W	Janela deslizante usada na avaliação dos antígenos	2	2, 3 e 4
α_1	Área de ambiguidade do Espaço <i>nonsel</i>	0.4	3
α_2	Área de ambiguidade do Detector APC	0.5	3
P	Ponderação no caso da detecção ser decidida aleatoriamente	0.95	3
L_s	Limiar de domínio <i>self</i> não infeccioso	0.4	4
L_n	Limiar de domínio <i>nonsel</i> infeccioso	0.5	4

5 Resultados

Os testes referidos na seção anterior foram testados e avaliados conforme a taxas de detecção (**td**) e de alarmes falsos (**taf**) e o tempo médio de detecção (\bar{t}) das falhas simuladas. Com isso, foram obtidos os resultados da Tabela 5.

Os resultados obtidos mostram que os algoritmos imunoinspirados alcançaram um desempenho favorável quanto à detecção das falhas nas simulações do motor

Table 4. Parâmetros usados pelo STLRA e suas variações.

Variável	Descrição	Valor usado	Algoritmos
N_c	População de células APC	20	5 e 6
T_i	Tempo de vida da célula APC	5	5 e 6
W	Janela deslizante usada na avaliação dos antígenos	2	5 e 6
T_c	Limiar de detecção usado pelo detector APC	1 (Testes 1-2) 0.3 (Teste 3)	6

Table 5. Resultado das simulações.

Algoritmo	Teste	td	taf	\bar{t}
1	1	100	0	0.0633s
	2	100	0	0.0674s
	3	71	0	0.3050s
2	1	100	0	0.0343s
	2	100	0	0.0666s
	3	95	0	0.3025s
3	1	100	0	0.0555s
	2	100	0	0.0666s
	3	95	0	0.3027s
4	1	100	0	0.0129s
	2	100	0	0.0666s
	3	95	0	0.3026s
5	1	100	0	0.0737s
	2	83	0	1.0243s
	3	100	0	0.3008s
6	1	100	0	0.2023s
	2	100	0	0.7466s
	3	85	0	0.3055s

de corrente contínua. No caso do motor de indução, o Algoritmo 1 não conseguiu detectar algumas falhas, e as abordagens baseadas no CSPRA (2 – 4) apresentaram melhorias neste caso. No caso do STLRA, a estratégia 5 conseguiu realizar a detecção em todos os casos, enquanto que a estratégia 6 deixou de detectar alguns testes.

Todos os testes apresentaram taxas de alarme falsos nulas e tempos de detecção razoáveis, isso significa que todos os algoritmos tiveram desempenho similares. O desempenho do reconhecimento antigênico nebuloso foi aprimorado com seu emprego nos algoritmos CSPRA e STLRA, pois ambos proveram uma detecção mais rápida das falhas, principalmente o 5 (STLRA usando o resíduo como sinal), que também foi o algoritmo mais rápido nos testes.

O STLRA pode ser considerado o método mais eficaz da abordagem, pois providenciou uma avaliação mais rápida dos dados. Pois em comparação com os demais algoritmos, o tempo de execução dos testes foi menor. O CSPRA e suas variações possuem uma desvantagem neste quesito, pois o tempo de execução é mais longo, apesar do desempenho satisfatório obtido.

6 Conclusão e Propostas de Continuidade

Neste trabalho foi avaliado o desempenho de três abordagens imunoinspiradas: o método do reconhecimento antigênico nebuloso e sua utilização em dois algoritmos inspirados no modelo do *nonsel*f infeccioso: o CSPRA e o STLRA, que realizam a detecção de falhas utilizando-se do mesmo princípio: considerando

um detector adicional que determina como a resposta imune acontecerá, porém, de formas completamente diferentes.

Os dois métodos podem apresentar resultados promissores na tarefa de detectar anomalias, inclusive falhas incipientes, e são boas extensões para o reconhecimento antigênico nebuloso, capaz de modelar o espaço *nonsel*. Porém ainda não possuem a função de diagnóstico das falhas, o que poderá ser considerado e devidamente implementado em possíveis abordagens futuras.

Além disso, foi possível a detecção de falhas incipientes através dos algoritmos estudados, o que revela um desempenho satisfatório das abordagens estudadas nos problemas avaliados. Comparações com outras abordagens e até mesmo o emprego de outras abordagens imunoinspiradas podem enriquecer o estudo dos problemas estudados neste trabalho e de outros problemas de detecção de falhas.

Agradecimentos. O trabalho contou com o apoio financeiro das agências financiadoras CAPES, CNPq e FAPEMIG. Agradecimentos à Profa. Lane Baccarini (UFSJ) pelas considerações referentes ao Benchmark do Motor de Indução.

References

1. Costa Silva, G.; Dasgupta, D.: A Survey of Recent Works in Artificial Immune Systems. In: Angelov, P. P. (eds.) Handbook on Computational Intelligence, Vol. 2, pp. 547–586. World Scientific (2016).
2. de Castro, L. N., Timmis, J.: Artificial Immune Systems: A New Computational Intelligence. Springer Science & Business Media, (2002).
3. Forrest, S.; Perelson, A. S.; Allen, L.; Cherukuri, R. "Self-nonsel discrimination in a computer," Proceedings of IEEE Computer Society Symposium on Research in Security and Privacy, Oakland, CA, pp. 202–212, (1994).
4. Janeway Jr., C. A., The immune system evolved to discriminate infectious nonself from noninfectious self. Immunology Today 13 (1), pp. 11–16, (1992).
5. Matzinger, P. The danger model: A renewed sense of self. Science 296, pp. 301–305, (2002).
6. Dasgupta, D.; Yu, S.; Nino, F., Recent Advances in Artificial Immune Systems: Models and Applications, Applied Soft Computing, Volume 11, Issue 2, Pages 1574–1587, (2011).
7. Chao, D.L.; Davenport, M.P.; Forrest, S.; Perelson, A.S., A stochastic model of cytotoxic T cell responses. Journal of Theoretical Biology 228, pp. 227–240, (2004).
8. Leng, Q.; and Bentwich, Z., Beyond self and nonself: Fuzzy recognition of the immune system. Scandinavian Journal of Immunology, 56, pp. 224–232, (2002).
9. Costa Silva, G.; Palhares, R. M.; Caminhas, W. M., Immune inspired Fault Detection and Diagnosis: A fuzzy-based approach of the negative selection algorithm and participatory clustering. Expert Systems with Applications, 39 (16), pp. 12474–12486, (2012).
10. Costa Silva, G.; Palhares, R. M.; Caminhas, W. M., Classificador de padrões imunoinspirado baseado no modelo do reconhecimento nebuloso de antígenos. 2o. Congresso Brasileiro de Sistemas Fuzzy, pp. 212–225, (2012).
11. Yu, S.; Dasgupta, D., Conserved self pattern recognition algorithm. In: Proceedings of the 7th international conference on artificial immune systems, ICARIS, pp 279–290, (2008).

12. Bevan, M.J., Altered Self, Altered World, *The Journal of Immunology*, 173, 2897–2898, (2004).
13. Yu, S.; Dasgupta, D., An empirical study of Conserved Self Pattern Recognition Algorithm: Comparing to other one-class classifiers and evaluating with random number generators, *Nature & Biologically Inspired Computing*, 2009. NaBIC 2009. World Congress on, Coimbatore, pp. 403–408, (2009).
14. Yu, S.; Dasgupta, D., An effective network-based Intrusion Detection using Conserved Self Pattern Recognition Algorithm augmented with near-deterministic detector generation, *2011 IEEE Symposium on Computational Intelligence in Cyber Security (CICS)*, Paris, pp. 17–24, (2011).
15. Twycross, J.; Aickelin, U.; Whitbrook, A., Detecting anomalous process behaviour using second generation artificial immune systems. *International Journal of Unconventional Computing* 6, pp. 301–326, (2010).
16. Kapsenberg, M., Dendritic-cell control of pathogen-driven T-cell polarization. *Nat Rev Immunol* 3 (12), pp. 984–993, (2003).
17. Azmi, R.; Pishgoo, B., STLR: A novel danger theory based structural TLR algorithm. *The ISC International Journal of Information Security* 5 (2), pp. 209–225, 2013.
18. Dangelo, M. F. S. V.; Palhares, R. M.; Caminhas, W. M.; Takahashi, R. H. C.; Maia, R. D.; Lemos, A. P.; Inacio, M. J. (2010). Detecção de falhas: uma revisão com aplicações, *Congresso Brasileiro de Automática* 2010.
19. Baccarini, L.M.R.; Menezes, B.R.; Caminhas, W.M., Fault induction dynamic model suitable for computer simulation: Simulation results and experimental validation. *Mechanical Systems and Signal Processing*, 24(1), pp. 300–311, (2010).
20. D’Angelo, M.F.S.V.; Palhares, R.M.; Takahashi, R.H.C.; Loschi, R.H.; Baccarini, L.M.R.; Caminhas, W.M., Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach, *Applied Soft Computing*, 11(1), Pages 179–192, (2011).