

Sistema Imunológico Artificial com Parâmetros *Fuzzy*

Luiz Antonio Carraro, Angelita Maria De Ré (Orientadora)

Departamento de Ciência da Computação
Universidade Estadual do Centro-Oeste –Paraná
Guarapuava –Brasil

lacarraro@gmail.com , amdre65@yahoo.com.br

Resumo: Os *Artificial Immune Systems* (Sistemas Imunológicos Artificiais - SIA) são constituídos a partir de técnicas inspiradas na teoria do sistema imunológico biológico. O princípio da seleção clonal garante a adaptação do organismo para combater antígenos invasores através de uma resposta imunológica ativada pelo reconhecimento entre o antígeno e o anticorpo. Esta resposta pode ser ativada mesmo com um reconhecimento aproximado, indicando que um Sistema *Fuzzy* pode ser utilizado para controlar este processo. Neste artigo é apresentado um modelo híbrido baseado em SIA e Sistemas *Fuzzy*, seguido da implementação e testes de um algoritmo aplicado à otimização multimodal e outro ao reconhecimento de padrões. Os resultados obtidos demonstram que o modelo proposto pode ser aplicado ao reconhecimento de padrões de forma satisfatória, entretanto, não se mostrou adequado para a otimização multimodal.

Palavras-Chave: Sistemas Imunológicos Artificiais, Sistemas *Fuzzy*, Otimização multimodal, Reconhecimento de padrões.

Abstract: *Artificial Immune Systems (AISs) are made of techniques inspired by the theory of the human body immune system. The principle of clonal selection ensures the adaptation of the body to fight invading antigens by an immune response activated by recognition between the antigen and antibody. An immune response can be activated even with an approximate recognition is found, indicating that a Fuzzy System can be used to control this process. This paper presents a hybrid model based on AIS and Fuzzy Systems, followed by implementation and testing of two algorithm applied to multimodal optimization and ther algorithm for pattern recognition. The result shows that the proposed model can be applied to pattern recognition in a satisfactory manner, however, was not suitable for multimodal optimization.*

Keywords: *Artificial Immune Systems, Fuzzy Systems, Multimodal Optimization, Pattern Recognition.*

1. Introdução

A dificuldade em resolver problemas com formulação matemática complexa por algoritmos clássicos levou a um grande interesse pelo estudo de técnicas alternativas inspiradas em organismos e sistemas biológicos. Dentre estas destacam-se as Redes Neurais Artificiais, Algoritmos Genéticos, e recentemente, Sistemas Imunológicos Artificiais. O sistema imunológico é formado essencialmente por um complexo de células, moléculas e órgãos, sendo assim capaz de tarefas como: reconhecimento de padrões, aprendizado, aquisição de memória, geração de diversidade, tolerância a ruídos e otimização. A partir de estudos dos sistemas imunológicos, novas técnicas computacionais estão sendo estudadas e aplicadas para resolver problemas de engenharia, o que deu origem a chamada Engenharia Imunológica [1].

Sabe-se que para que o sistema imunológico seja capaz de se recuperar de um ataque antigênico, ele deve primeiro ser capaz de reconhecer, mesmo que parcialmente, o antígeno que o atacou [2]. As células do anticorpo que reconhecerem o antígeno serão selecionadas para a clonagem, e assim, o antígeno poderá ser eliminado do organismo. Assim, esta resposta imunológica é ativada mesmo quando a ligação entre o antígeno e o anticorpo não é completa, indicando a presença de incertezas no sistema imunológico, sugerindo que a utilização de um Sistema *Fuzzy* associado ao Sistema Imunológico Artificial deve ser apropriada para modelar esta característica biológica [3].

Os Sistemas *Fuzzy* são conhecidos por fornecer respostas refinadas e adaptadas ao contexto em que foram inseridos, sendo adequados em diversas situações onde informações incertas estejam presentes. Devido a este ajuste fino, *Fuzzy* foi utilizado em conjunto com outras técnicas de Inteligência Artificial, como Sistemas Especialistas, Redes Neurais Artificiais, Algoritmos Genéticos dentre outros. Existem ainda pesquisas que utilizam Algoritmos Evolutivos com parâmetros *Fuzzy*.

Neste artigo é apresentado o desenvolvimento de uma pesquisa sobre as influências que a aplicação de um Sistema *Fuzzy* pode ter sobre o SIA. Para tanto, descreve a implementação, testes e avaliação de um novo modelo híbrido para a resolução de problemas. O documento está organizado da seguinte forma: a Seção 2 apresenta um estudo sobre o Sistema Imunológico Artificial, com foco nos algoritmos estudados. Na Seção 3 são apresentados trabalhos correlatos a este. Na Seção 4 é apresentada a metodologia utilizada para o desenvolvimento seguida de duas aplicações do modelo híbrido. Na Seção 5 são apresentados e discutidos os resultados obtidos de forma específica para os dois algoritmos implementados. Por fim, a Seção 6 apresenta as conclusões e trabalhos futuros.

2. Sistemas Imunológicos Artificiais

Os Sistemas Imunológicos Artificiais (SIA) são compostos por modelos inspirados na atividade do Sistema Imunológico Biológico em um organismo. Tais modelos apresentam características adaptativas e evolutivas, sendo possível então a criação de algoritmos imuneinspirados com as mesmas capacidades [4][5]. Esta técnica constitui uma bioinspiração e faz parte da área da Computação Natural, que surgiu como uma nova área de pesquisa na computação nas últimas décadas [6].

No ano de 2001, [5] formalizou a Engenharia Imunológica (EI). Seu objetivo principal era definir ferramentas para a solução de problemas baseadas no sistema imunológico, ainda que para isso, as ferramentas perdessem parcialmente a sua fidelidade ao sistema imunológico biológico. As contribuições deste trabalho [5] vêm sendo amplamente utilizadas por pesquisadores e os resultados estão presentes na literatura. E, para a aplicação desta metodologia, algumas formalizações se fazem

necessárias como a definição de um espaço de formas para a representação. Com isso, é possível definir também o método utilizado para a geração do repertório de células e também como medir a afinidade entre antígenos e anticorpos.

2.1 Espaço de Formas e Medidas de Afinidade

Na formalização de problemas com o fim de resolvê-los através de SIA é necessário pensar em um meio de representação. Para tal, um espaço de formas pode ser definido para modelar o anticorpo e o antígeno. O espaço de formas utilizado na modelagem irá parcialmente determinar a medida de afinidade a ser utilizada [3]. Isto é, matematicamente, uma célula (m) tanto anticorpos (Ab) quanto antígenos (Ag) pode ser representada por uma *string* de atributos (conjunto de coordenadas) $m = \langle m_1, m_2, \dots, m_L \rangle$ $m \in S^L$. Também, existem ainda estruturas mais complexas, como as utilizadas na aplicação de SIA para inicialização de pesos de redes neurais.

Como a afinidade entre um anticorpo e um antígeno está relacionada à distância entre eles, ela poderá ser estimada através de qualquer medida de distância entre duas *strings* ou vetores, como a distância Euclidiana (Equação 1), de Manhattan (Equação 2), ou de Hamming (Equação 3) [5], [3].

$$D = \sqrt{\sum_{i=1}^L (Ab_i - Ag_i)^2} \quad (1)$$

$$D = \sum_{i=1}^L |Ab_i - Ag_i| \quad (2)$$

$$D = \sum_{i=1}^L \delta_i \quad \text{onde } \delta_i = \begin{cases} 1 & \text{se } Ab_i \neq Ag_i, \\ 0 & \text{caso contrário} \end{cases} \quad (3)$$

2.2 Algoritmos Imunológicos Artificiais

Tendo como objetivo a aplicação de sistemas *fuzzy* no SIA, dois algoritmos foram estudados. O primeiro algoritmo é baseado no princípio da seleção clonal, e segundo na teoria das redes imunológicas.

O algoritmo de seleção clonal é baseado no mecanismo básico de resposta imunológica ativada por um estímulo antigênico. Estabelece ainda a idéia de que somente as células que reconhecem os antígenos são selecionadas para a proliferação. Durante a seleção clonal as células são expostas a um processo de maturação de afinidade, que deve melhorar a capacidade de combate ao antígeno invasor.

Em [7] os autores propuseram um algoritmo de seleção clonal levando em conta como principais aspectos imunológicos: células de memória; seleção e clonagem das células mais estimuladas; eliminação (morte) das células não estimuladas; maturação de afinidade e seleção dos clones com maior afinidade; gerações e manutenção da diversidade; mutação proporcional à afinidade da célula. Este algoritmo mais tarde foi denominado CLONALG (*Clonal Selection Algorithm*) [5], aplicado a reconhecimento de padrões e otimização.

A partir da teoria das redes imunes foi proposto por Castro e Zuben [5], o algoritmo aiNet (*Artificial Immune Network*) que é um grafo com pesos, não necessariamente conectado completamente. É composto por um conjunto de nós

chamados de anticorpos, e pares de nós chamados de arestas, com um número associado chamado de peso, ou força de conexão. Os anticorpos devem representar a imagem interna dos patógenos ao qual o algoritmo foi apresentado. A conexão entre os anticorpos deve determinar as suas interrelações, provendo um grau de similaridade (em um dado espaço métrico) entre eles, ou seja, quanto mais perto estiverem, maior a similaridade. O modelo aiNet foi proposto como uma combinação do modelo de seleção clonal e da teoria das redes imunológicas [1]. É possível dizer que o aiNet é uma extensão do algoritmo CLONALG com passos envolvendo a interação das células da rede imunológica umas com as outras [8]. Em sua proposta inicial, o algoritmo aiNet foi aplicado a classificação e clusterização de dados para a análise, através do repertório de células ao final da execução do algoritmo. Mas como o algoritmo de seleção clonal (CLONALG) está presente no aiNet como parte de seu processamento, em [9] os autores propuseram a versão do aiNet para a otimização de funções, conhecida como opt-aiNet.

3. Trabalhos Correlatos

A combinação ou hibridização de técnicas tornou possível a criação de várias soluções sofisticadas e bem sucedidas para problemas complexos do mundo real [10]. E, Zadeh [11] afirma que esta abordagem, conhecida como computação flexível, não consiste de uma mistura de técnicas, e sim de uma parceria em que cada parceiro contribui com uma metodologia diferente para o domínio do problema, de forma a complementar a estratégia de solução.

Assim, com o objetivo de tratar deficiências de outros modelos de Sistemas Imunológicos Artificiais, em [12] é proposto um modelo de Sistemas Imunológicos Artificiais *Fuzzy* com aplicação a clusterização e a *Web Profiling*. Os autores introduzem o conceito de incerteza no processo de verificação de compatibilidade entre anticorpos e antígenos e propõem um sistema híbrido. O modelo resultante imita o aprendizado adaptativo e o mecanismo de defesa do sistema imunológico e foi utilizado como sistema de monitoramento e aprendizado para um Web site, frente às requisições Web.

Em [5], o autor propôs um algoritmo baseado na teoria das redes imunológicas para realizar análise de dados e clusterização. Neste os clusters foram representados pelos seus centróides, o que permitiu a inclusão de funções de pertinência para cada célula imunológica em relação a um determinado cluster. Esse esquema de clusterização *fuzzy* indica que cada célula pertence a um único cluster e associa cada célula com cada cluster da rede, utilizando uma função de pertinência.

Em seu trabalho sobre a aplicação do efeito Baldwin (este efeito é o resultado da interação da evolução com a aprendizagem em indivíduos ao longo de suas vidas) no sistema imunológico, Hightower utilizou uma função não-linear (sigmoid) para determinar o valor de ligação (afinidade) entre duas moléculas[13]. Segundo o autor, uma função não-linear é mais plausível de um ponto de vista imunológico e é um requisito necessário para que ocorra o efeito Baldwin enquanto evolui um modelo de Sistema Imunológico Binário utilizando um algoritmo evolucionário.

Outro modelo de integração entre SIA e Sistemas *Fuzzy* foi proposto por [14]. Neste os autores propuseram um algoritmo imunológico baseado no princípio de seleção clonal, com o objetivo de evoluir regras de classificação *fuzzy* onde cada anticorpo equivale a uma regra.

4. Algoritmo *Imunofuzzy*

A afinidade se refere ao grau de ligação entre o anticorpo e o antígeno. Quanto maior a afinidade, mais forte é a ligação e conseqüentemente melhor é o reconhecimento e a resposta imunológica. Considerando este fator, Castro [3] argumentou que o reconhecimento de um antígeno pelo sistema imunológico é aproximado, portanto uma resposta imunológica pode ser ativada mesmo quando a ligação entre um antígeno e um anticorpo não é perfeita, ou seja, uma ligação aproximada foi encontrada. Isso demonstra que a imprecisão está presente no SIA e que a inclusão de um Sistema *Fuzzy* pode ser adequada para modelar alguns aspectos imunológicos [10].

Tendo isso em vista, é possível perceber que o modelo em que o reconhecimento antigênico possui maior influencia é o algoritmo de seleção clonal, pois é o fator responsável pela ativação de uma resposta imunológica efetiva. A intensidade com que a resposta imunológica será ativada é totalmente dependente do grau de afinidade entre o antígeno e o anticorpo que o reconheceu, ou seja, quanto melhor o reconhecimento, mais intensa e veloz será a resposta. Partindo deste princípio, foram estudados neste trabalho os modelos CLONALG - [7] e aiNet [5]. Estes são dois algoritmos presentes na literatura que foram inspirados no princípio da seleção clonal e redes imunes. O CLONALG é a própria implementação computacional do modelo de seleção clonal. Por outro lado, o aiNet utiliza o algoritmo de seleção clonal como parte do seu processamento, utilizando ainda conceitos da teoria das redes imunológicas para controlar a dimensão da rede, e conseqüentemente economizar recursos.

Uma resposta imunológica pode ser ativada mesmo quando a ligação entre o antígeno e o anticorpo não é perfeita. No algoritmo de seleção clonal, as células com maiores afinidades serão selecionadas para a clonagem e mutação, porém o termo “maiores afinidades” expressa a presença da incerteza sobre quando uma célula possui uma afinidade “alta”, “média”, ou “baixa” com o antígeno. O algoritmo proposto nesta pesquisa o tratamento da referida incerteza.

Como base para o desenvolvimento do algoritmo *immunofuzzy* foram utilizados os algoritmos CLONAL e aiNet, ambos por serem baseados no princípio da seleção clonal. Dessa forma, ambos os algoritmos possuem a etapa de seleção das células do repertório que melhor reconhecem o antígeno apresentado para a clonagem e maturação de afinidade. Quanto melhor o reconhecimento do antígeno, maior será a sua proliferação de clones e menor será a sua taxa de mutação. Com isso é possível inserir regras para a intensidade de proliferação e taxa de mutação das células ativadas, como as apresentadas na Tabela 1.

Tabela 1. Regras para a proliferação de anticorpos.

Afinidade	Proliferação (Intensidade)	Taxa de Mutação
Baixa	Baixa	Alta
Média	Média	Média
Alta	Alta	Baixa

O sistema imunológico melhora constantemente a sua afinidade com os antígenos que o atacam, seja através da recuperação a um ataque ou de novas exposições ao antígeno. Este conceito aplicado ao desenvolvimento de algoritmos envolve a constante apresentação do antígeno (padrão a reconhecer ou função a otimizar) ao SIA, que no decorrer das gerações melhora a capacidade de reconhecimento antigênico (afinidade). Dessa forma, as funções de pertinência não devem ser definidas de forma estática (sem alterações em tempo de execução), pois no decorrer das iterações os níveis de afinidade são conseqüentemente melhorados e as

funções de pertinência estáticas podem não ser capazes de classificar alguns antígenos. Tendo isso em vista, as funções de pertinência (conjuntos) do Sistema *Fuzzy* devem ser modificadas a cada nova iteração do algoritmo, de forma dinâmica. A Figura 1 demonstra a modificação dos conjuntos no decorrer de quatro iterações.

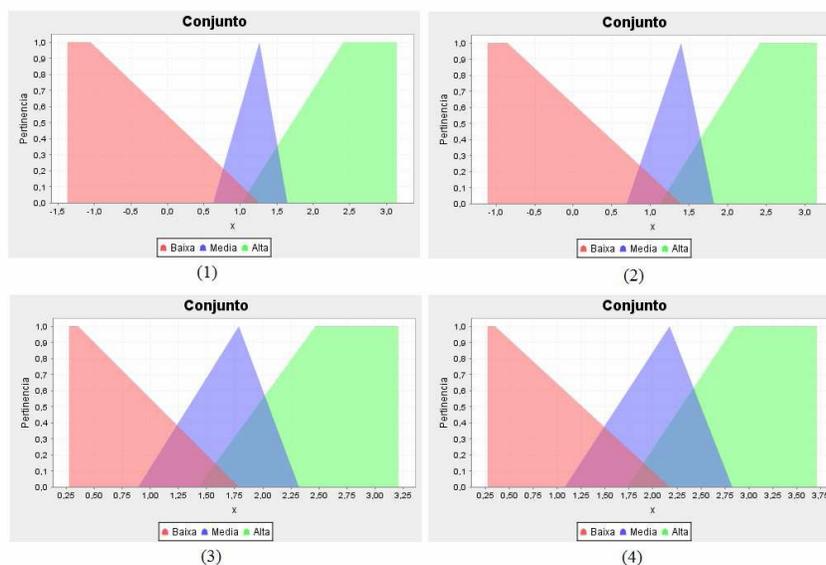


Figura 1. Evolução dos conjuntos em quatro iterações.

Para verificar os efeitos que a inclusão de um modelo *fuzzy* em SIA na resposta imunológica em relação a um anticorpo foram desenvolvidos dois algoritmos *imunofuzzy*. Ambos os algoritmos são aplicados a problemas reais existentes na literatura, sendo estes a otimização de funções multimodais e o reconhecimento de padrões. A modelagem destes algoritmos é apresentada na sequência.

4.1 Aplicação à otimização de funções multimodais

Funções multimodais geralmente possuem vários ótimos locais e um ou mais ótimos globais. Em diversos casos, pode ser necessário ou importante localizar estes diversos pontos ótimos e, conseqüentemente, o algoritmo de solução deve se encarregar de evitar a convergência prematura a um ótimo local.

Os algoritmos evolucionários aparentam ser uma das abordagens mais atrativas para esta classe de problemas por serem técnicas baseadas em população, podendo encontrar múltiplas soluções candidatas em apenas uma execução.

Em [5] é apresentado o algoritmo de seleção clonal (CLONALG) para a otimização multimodal. Neste o autor compara os resultados obtidos pelo algoritmo proposto com os resultados da literatura, gerados por um Algoritmo Genético e por um Algoritmo Genético com *fitness* compartilhado. Posteriormente, em [9] os autores propõem uma adaptação do algoritmo aiNet originalmente proposto para compressão de informações e clusterização de dados a otimização multimodal. Assim, nesta pesquisa, tendo como base as pesquisas desenvolvidas, foi proposto uma adaptação dos algoritmos para a utilização de um Sistema *Fuzzy* como apresentado no diagrama de blocos da Figura 2 e descrito na sequência:

- 1) Iniciar uma população de anticorpos randomicamente (o número inicial de anticorpos não é relevante) e inicializa o Sistema *Fuzzy*.

- 2) Calcular o fitness de cada anticorpo. O fitness é calculado através do resultado gerado pela função que se está buscando otimizar.
- 3) Calcular a média dos fitness da população e selecionar o fitness da pior e da melhor célula anticorpo.
- 4) Modificar as funções de pertinência do Sistema *Fuzzy* utilizando os resultados do Passo 3.
- 5) Gerar clones para cada anticorpo. O número de clones por anticorpo é baseado na resposta do Sistema *Fuzzy* responsável pela avaliação do anticorpo. Quanto melhor o anticorpo, mais intensa é a proliferação.
- 6) Modificar (mutação) cada clone, proporcionalmente, com o fitness do anticorpo que o gerou, utilizando a Equação 4.
- 7) Determinar o fitness de todos os indivíduos da população de clones
- 8) Selecionar para cada clone o anticorpo com maior fitness e calcular a média do fitness da população.
- 9) Se o erro médio da população não for significativamente diferente da iteração prévia, então retorne ao Passo 2 Senão, continuar.
- 10) Calcular a afinidade entre todos os anticorpos da rede.
- 11) Eliminar (supressão) todos os anticorpos, exceto os com maiores fitness daqueles cuja afinidade é menor que o limiar de supressão.
- 12) Determinar o número de células, denominadas células de memória, após a supressão.
- 13) Introduzir uma porcentagem de anticorpos gerados randomicamente e retornar ao Passo 2.

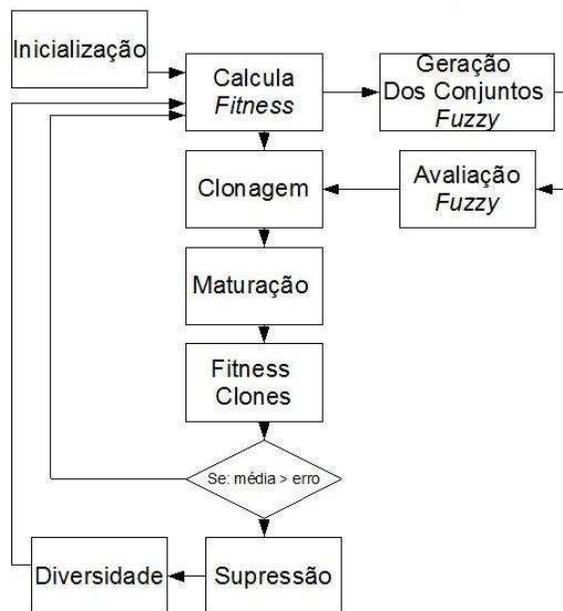


Figura 2 – Diagrama do algoritmo opt-aiNet com as modificações propostas.

O algoritmo proposto possui dois passos a mais do que original. O Passo 3 possui o objetivo de selecionar e calcular os valores que serão utilizados para a modificação dos conjuntos *fuzzy*, que neste caso são: a célula com pior *fitness*, a com o melhor *fitness* e a média dos *fitness* da população. O Passo 4 deve modificar os valores que definem os conjuntos *fuzzy* utilizando os valores obtidos no Passo 3. Conseqüentemente, no Passo 5

a avaliação dos anticorpos passa a ser responsabilidade do Sistema *Fuzzy*, sendo assim, células classificadas como mais afins devem se proliferar mais do que as classificadas com menor afinidade.

No Passo 6 a mutação proporcional à afinidade é realizada como proposto em [9] de acordo com a Equação 4, onde c' é um anticorpo após a mutação, $N(0,1)$ é uma variável Gaussiana randômica, β é um parâmetro que controla o decremento da função exponencial inversa e f^* é o fitness de um anticorpo normalizado no intervalo [0,1].

$$\begin{aligned} c' &= c + \alpha N(0,1), \\ \alpha &= (1/\beta) \exp(-f^*) \end{aligned} \quad (4)$$

No Passo 11 a afinidade entre duas células da rede imunológica deve ser calculada utilizando a distância Euclidiana (Equação 1).

4.2 Aplicação ao reconhecimento de padrões

O sistema imunológico possui a capacidade de aprendizado, generalização e aquisição de memória. Com base nesta premissa, em [5] é proposto o algoritmo de seleção clonal (CLONALG). Para a validação da sua funcionalidade, o autor testou o algoritmo aplicando-o ao reconhecimento de caracteres. Para o problema de reconhecimento de padrões, é suposta a existência de um repertório inicial aleatório de anticorpos com a finalidade de reconhecer uma população conhecida de antígenos. Neste caso, os antígenos devem ser os padrões a serem reconhecidos pelo algoritmo. O algoritmo de seleção clonal foi modificado para a inclusão de um sistema *Fuzzy* como apresentado no diagrama de blocos da Figura 3 e nos oito passos descritos na sequência:

- 1) Gerar um conjunto (P) de soluções candidatas, composto de um subconjunto de células de memória (M) e o resto da população (P_r). Ou seja, $P = M + P_r$;
- 2) Calcular a afinidade entre o antígeno e os anticorpos da população.
- 3) Calcular a média das afinidades dos anticorpos da população e selecione a afinidade da pior e da melhor célula anticorpo.
- 4) Modificar as funções de pertinência do Sistema *Fuzzy* utilizando os resultados do Passo 2.
- 5) Reproduzir (clonar) os indivíduos da população P_n , gerando uma nova população de clones. A quantidade de clones por célula é definida com base na avaliação do anticorpo pai pelo Sistema *Fuzzy*;
- 6) Submeter os clones a mutação, onde a mutação é proporcional à afinidade do anticorpo com o antígeno. Uma população de anticorpos maturados é gerada (C^*);
- 7) Re-selecionar os melhores indivíduos de C^* para compor o conjunto de memória M.
- 8) Substituir d anticorpos por novos, causando a introdução de diversidade. Quanto menor a afinidade da célula, mais a probabilidade de ser substituída.

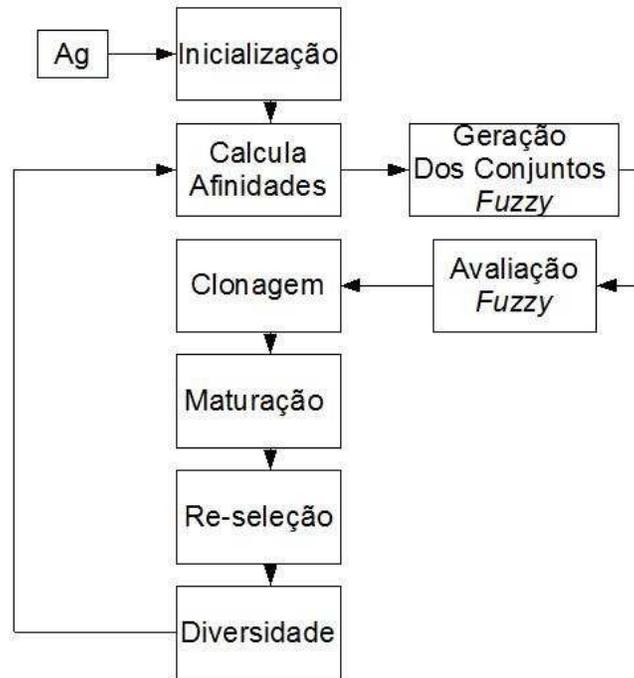


Figura 3 – Diagrama do algoritmo CLONALG clonal com as modificações propostas.

No algoritmo proposto, um dos passos foi removido, um novo passo foi inserido, e um passo foi modificado. De forma semelhante à apresentada no algoritmo anterior, no Passo 3 é calculada a média das afinidades dos anticorpos da população e, também, são selecionadas as células com menor e maior afinidade. O Passo 4 deve modificar os valores que definem os conjuntos *fuzzy* utilizando os valores obtidos no Passo 3. Dessa forma, no Passo 5 a quantidade de clones gerada por célula depende da classificação gerada pelo Sistema *Fuzzy*. O reconhecimento de padrões é realizado através da codificação binária, portanto o espaço de formas de Hamming é o mais adequado para ser utilizado na medida de afinidade entre anticorpos e antígenos.

5. Resultados e Discussão

Nesta seção são apresentados os resultados obtidos nos testes dos algoritmos propostos. Os algoritmos apresentados foram implementados utilizando a linguagem de programação Java no ambiente de desenvolvimento NetBeans. O equipamento onde os testes foram realizados consiste em um computador com processador Athlon 64 X2 1.8 e 2GB de memória RAM.

5.1. Otimização de funções multimodais

O algoritmo *imunofuzzy* desenvolvido para a otimização de funções multimodais foi aplicado a problema de otimização de duas variáveis $g(x,y) = x.\text{sen}(4\pi x) - y.\text{sen}(4\pi y + \pi) + 1$, ilustrado na Figura 4. Como é possível identificar pela figura, a função possui vários ótimos locais e somente um ótimo global.

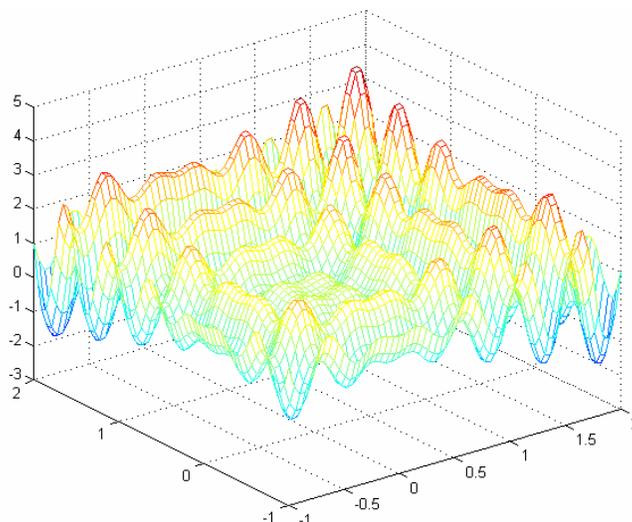


Figura 4. Função bidimensional $g(x,y) = x.\text{sen}(4\pi x) - y.\text{sen}(4\pi y + \pi) + 1$ a ser maximizada.

Para a execução do algoritmo foram utilizados os seguintes parâmetros de entrada: 5 células iniciais; 500 clones; 20 iterações; limiar de supressão da rede de 2.0; limiar de erro de 0.0001; 1% de inserção de diversidade; e limitantes inferior e superior de $[-1,2]$ para x e y .

O número inicial de células não é relevante neste algoritmo, pois a quantidade de anticorpos presente na população é controlada pela própria rede. Dessa forma, mesmo que o algoritmo seja inicializado com 5 células é possível que o mesmo termine a sua execução com uma quantidade de células completamente diferente.

O número máximo de clones que uma célula poderá gerar é 500. A quantidade de clones gerada por célula é calculada pelo Sistema *Fuzzy* associado ao algoritmo. Diferentemente do modelo proposto em [5], a reprodução proporcional à afinidade não necessariamente se aplica, significando que a quantidade de clones gerada para cada um dos anticorpos é considerada a mesma, não privilegiando anticorpo algum por sua afinidade.

Com base nos testes realizados foi possível perceber que com esta mudança na estrutura do algoritmo, os anticorpos que antes eram analisados localmente, independentemente das suas afinidades, agora são muitas vezes considerados com menor importância. Com a priorização das células mais estimuladas, o algoritmo perdeu o seu caráter de otimização multimodal, passando a buscar competitivamente pelo ótimo global da função.

5.2. Reconhecimento de padrões

Uma aplicação muito comum e útil é o reconhecimento de padrões. Como apresentado anteriormente, o sistema imunológico possui grande capacidade de aprendizado, reconhecimento e adaptação. São basicamente estes motivos que justificam o desenvolvimento do algoritmo de seleção clonal para o reconhecimento de padrões. A segunda aplicação do presente trabalho envolve a implementação do algoritmo CLONALG [7] para o reconhecimento de caracteres em padrões de imagens.

Os padrões utilizados como antígenos a serem apresentados ao sistema imunológico são arquivos no formato Bitmap, que são convertidos em vetores de bits com comprimento 100. O exemplo da Figura 5 apresenta como um padrão é

apresentado e como o sistema imunológico o deve reconhecer, através da complementaridade.

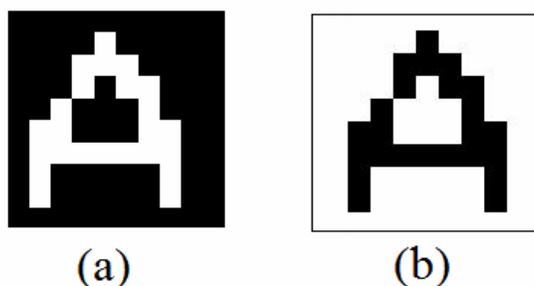


Figura 5. (a) Antígeno apresentado ao sistema imunológico. (b) Reconhecimento pela complementaridade.

Para a execução do algoritmo foram utilizados os seguintes parâmetros: 10 células anticorpos; 50 iterações; 40% de inclusão de diversidade; e 0.85 para o fator de mutação. É importante ressaltar que o fator de mutação é utilizado com proporcionalidade ao nível de afinidade da célula. Quanto maior a afinidade, menor a taxa de mutação e vice-versa. A Figura 6 apresenta o reconhecimento final do algoritmo (utilizando os parâmetros descritos anteriormente) em seis execuções distintas, das quais 3 utilizam o algoritmo *immunofuzzy*.

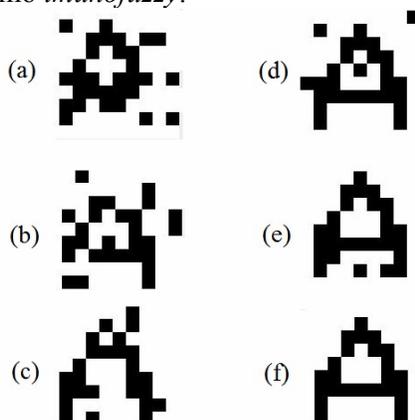


Figura 6. Resultado final do algoritmo em 6 execuções distintas. (a), (b) e (c): Algoritmo de Seleção Clonal Clássico. (d), (e), e (f): Algoritmo Immunofuzzy.

Para a verificação da eficácia do algoritmo *immunofuzzy* desenvolvido para esta aplicação, uma bateria de testes foi realizada com o intuito de comparar resultados entre o novo algoritmo e o clássico. A Tabela 2 apresenta a relação da taxa de reconhecimento entre os dois algoritmos para seis casos de testes, utilizando um repertório de 10 células, e máximo de 4 clones por célula.

Tabela 2. Testes comparativos.

Teste	Iterações	Diversidade	F. de Maturação	Reconhecimento (Clássico)	Reconhecimento (<i>Imunnofuzzy</i>)
1	50	40%	0.85	90%	97%
2	50	40%	0.5	88%	91%
3	50	20%	0.5	82%	90%
4	50	20%	0.25	86%	88%
5	50	40%	0.25	80%	86%

Com base nos 5 casos de teste apresentados na Tabela 2 é possível perceber que para 50 iterações de aprendizado o reconhecimento final do antígeno através do algoritmo *imunofuzzy* foi maior que o do algoritmo clássico. Para o caso da utilização de 100 iterações, o reconhecimento total do antígeno (100%) foi alcançado pelos dois algoritmos, porém em iterações diferentes, como apresentado na Tabela 3.

Tabela 3 – Iteração na qual o reconhecimento total foi alcançado.

Teste	Clássico	<i>Imunofuzzy</i>
1	72	54
2	74	59
3	80	52
4	77	50
5	75	55

6. Conclusões e trabalhos futuros

O princípio de seleção clonal é utilizado para descrever as características básicas de uma resposta imune adaptativa a estímulos antigênicos. Este princípio estabelece a idéia de que somente as células capazes de reconhecer antígenos irão se proliferar, sendo selecionadas em detrimento das outras menos estimuladas. Durante a reprodução celular, os clones estão sujeitos a um processo de mutação com taxas elevadas que, juntamente com uma forte pressão seletiva, resultará no aumento da afinidade entre o anticorpo e o antígeno que o selecionou.[15]

No decorrer deste trabalho foram apresentados conceitos sobre reconhecimento de padrões e otimização no SIA, em que os processos de seleção e maturação são responsáveis pela geração de indivíduos cada vez melhores adaptados ao ambiente no qual estão inseridos. Assim, na seqüência foram propostos dois algoritmos *imunofuzzy*, aplicados a otimização multimodal e ao reconhecimento de padrões. Pode-se concluir que o algoritmo *imunofuzzy* proposto não é adequado para a otimização multimodal, uma vez que ótimos locais são desconsiderados. Em contrapartida, o algoritmo aplicado ao reconhecimento de padrões demonstrou uma convergência ao reconhecimento completo em menos iterações que o algoritmo clássico.

Levando em conta os aspectos do processo de defesa biológico apresentados nesta pesquisa, assim como os algoritmos implementados, é possível concluir que a implementação computacional do algoritmo de seleção clonal em conjunto com um Sistema *Fuzzy* deve levar ao desenvolvimento de ferramentas adaptativas capazes de resolver problemas, e ainda assim, manter semelhança com o aspecto imunológico que lhe deu origem.

Com base na pesquisa elaborada é interessante destacar que existe muito para ser feito. Alguns destes trabalhos podem ser citados como sugestões de trabalhos futuros, tais como: um algoritmo *imunofuzzy* com o objetivo de estudar as influências que a classificação de anticorpos por regras *fuzzy* pode causar no efeito Baldwin; o estudo e aplicação de conceitos *fuzzy* em modelos de SIA como por exemplo o Algoritmo de Seleção Negativa.

Por fim, em [3] os autores discutem que o SIA é uma técnica passível de aplicação com outros modelos computacionais, como RNA e Algoritmos Evolucionários. Na literatura já existem trabalhos que envolvem este conceito, mas uma investigação mais aprofundada pode revelar a possibilidade de desenvolvimento de uma nova abordagem.

7. Referências Bibliográficas.

- [1] L. N. Castro, F. J. Zuben, *aiNet: An Artificial Immune Network for Data Analysis*. Idea Group Publishing. USA, 2001
- [2] C. Berek and M. Ziegner, *The maturation of the immune response*. Imm Today 14, p 400-402, 1993.
- [3] L. N. Castro and J. I. Timmis. *Artificial immune systems as a novel soft Computing*. Springer-Verlag 2003.
- [4] D. Dasgupta, *Artificial Immune Systems and Their Applications*. Springer-Verlag, 1998.
- [5] L. N. Castro, *Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais*. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas. 2001.
- [6] L. N. Castro, F. J. Zuben. *Artificial Immune Systems: Part 1 – Basic Theory And Applications*. Relatório Técnico – DCA 01/99. Universidade Estadual de Campinas, 1999.
- [7] L. N. Castro, F. J. Zuben. *The Clonal Selection Algorithm with Engineering Applications*. Workshop on Artificial Immune Systems and Their Applications. Las Vegas, 2000.
- [8] L. N. Castro, J. I. Timmis, *Artificial immune Systems: A New Computational Intelligence Paradigm*. Springer- Verlag, 2002.
- [9] L. N. Castro, J. I. Timmis, *An Artificial Immune Network for Multimodal Function Optimization*. Proceedings of IEEE Congress on Evolutionary Computation (CEC'02), 1 v, p. 699-674. Hawaii, 2002.
- [10] L. A. Carraro, A. M. De Ré, *Algoritmo Imunofuzzy: Um novo modelo de computação flexível*. II Jornada de Atualização em Informática da UNICENTRO. Guarapuava, 2009.
- [11] L. A. Zadeh, *What is soft computing?* Disponível em <http://www.soft-computing.de/def.html> . 2009.
- [12] O.Nasaroui et al. *The fuzzy artificial immune system: motivations, basic concepts, and application to clustering and Web profiling* Fuzzy Systems. Proceedings of the 2002 IEEE International Conference, 2002, p. 711 – 716
- [13] R.R. Hightower et al. *The baldwin effect in the immune system: learning by somatic hypermutation*. In: *Adaptive Individuals in Evolving Populations*. Addison-Wesley, p. 159–167,1996.

- [14] R.T. Alves *et al.* *An artificial immune system for fuzzy-rule induction in data mining*. In: *Parallel Problem Solving from Nature - PPSN VIII. Lecture Notes in Computer Science*, 3242. Springer-Verlag, p. 1011-1020, 2004.
- [15] L. N. Castro, *Fundamentals of natural computing: an overview*. ScienceDirect, 2006.