

# Melhorando a eficiência do algoritmo da rede imunológica artificial (aiNet) na construção de redes neurais artificiais com função de base radial

## Resumo

A Rede Imunológica Artificial (aiNet) é um algoritmo dos Sistemas Imunológicos Artificiais para clusterização que requer tempo de processamento significativo, como em sua aplicação na construção de Redes Neurais Artificiais com Função de Base Radial (RBF). Para construir RBF aplicando o aiNet, considerando a minimização do tempo de processamento e da taxa de erro, três estratégias são propostas: i) construir uma RBF a cada geração do aiNet, preservando a RBF de melhor desempenho; ii) refinar os anticorpos remanescentes a cada geração do aiNet pelo algoritmo *k-means*; e iii) dividir a matriz de memória de anticorpos do aiNet em matrizes menores, submetendo-as iterativamente ao processo de supressão. Estas estratégias se mostraram adequadas para minimizar uma medida erro e o tempo de processamento, considerando o aiNet padrão. Em dois experimentos de construção de RBF, o erro de classificação e o tempo de processamento foram minimizados em 5,39% e 89,91%, respectivamente.

**Palavras-chave:** Algoritmo da rede imunológica artificial. Sistemas imunológicos artificiais. Minimização de tempo de processamento. Minimização de taxa de erro. Redes neurais artificiais de função de base radial.

## Sandro Rautenberg

Departamento de Ciência da Computação – Universidade Estadual do Centro-Oeste (UNICENTRO)  
Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina, srautenberg@unicentro.br

## José Leomar Todesco

Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina, tite@egc.ufsc.br

## Abstract

The Artificial Immune Network (aiNet) is an Artificial Immune System algorithm for clustering tasks. Often, it requires significant processing time, as it is the case of applying in Radial Basis Function Neural Networks (RBFNN). In this work, to construct RBFNN applying the aiNet, attempting for minimize processing time, without increasing an error rate measure, three strategies are proposed: i) constructing RBFNN in each aiNet generation, preserving the RBFNN with the best performance; ii) refining the remained antibodies in each aiNet generation by the *k-means* algorithm; and iii) dividing the internal memory of clonal antibodies into smaller matrices, and submit them iteratively to the aiNet suppressing process. These strategies are showed suitable for minimizing the error rate and the processing time taking into account standard aiNet algorithm. In two RBFNN construction experiments, these strategies minimized the error rate and the processing time in 5,39% and 89,91%, respectively.

**Keywords:** Artificial immune network algorithm. Artificial immune systems. Time processing minimization. Error rate minimization. Radial basis function neural network.

## 1 Introdução

Com estudos iniciados há pouco mais de uma década, Sistemas Imunológicos Artificiais (SIA) constituem-se num novo campo de estudos da Inteligência Computacional (DASGUPTA, 2006), sendo definidos como sistemas adaptativos inspirados na teoria imunológica, nas funções imunológicas observáveis, nos princípios e modelos que são aplicados na resolução de problemas (TIMMIS, 2004). Reconhecimento de Padrões, Segurança Computacional, Robótica, Otimização, Controle, Abordagens Conexistas, Detecção de Falhas e Anomalias, Aprendizagem de Máquina estão dentre as aplicações de SIA (CASTRO, 2001).

Devido à atualidade dos SIA, Dasgupta (2006) aponta alguns aspectos pouco explorados para a tecnologia, o que dificulta a aplicação dos SIA como técnica de resolução em problemas reais. Dentre os aspectos enumera-se:

- a melhoria da eficiência dos algoritmos;
- o aumento da representação;
- a introdução de outros mecanismos imunológicos; e
- o desenvolvimento da arquitetura unificada que integre vários modelos de SIA.

No tocante ao primeiro aspecto, a melhoria da eficiência dos algoritmos dos SIA, pode-se destacar o algoritmo da Rede Imunológica Artificial - *Artificial Immune Network* (aiNet). Para os SIA, o aiNet apresenta, como característica principal, a capacidade de descrever a estrutura interna de um conjunto de dados, de acordo com a distribuição de probabilidade e as relações de vizinhança (CASTRO, 2001). Isso torna o algoritmo viável à aplicação, por exemplo, na construção de Redes Neurais Artificiais de Função de Base Radial (RBF), como visto em (CASTRO, ZUBEN, 2001; RAUTENBERG *et al*, 2006; e DIAO, PASSINO, 2002).

No contexto de melhoria do aiNet, Liu e Xu (2006) propuseram o *Unsupervised Optimal Fuzzy Clustering* aiNet (UOFC-aiNet), onde os parâmetros do aiNet são alterados dinamicamente de acordo com princípios da lógica difusa, melhorando a representatividade dos anticorpos.

Li *et al* (2007) propuseram o *Efficient Artificial Immune Network* (EaiNet) para otimização de funções. Esta versão do aiNet atrela uma espécie de aprendizado elitizado que é inspirado não somente do sistema imunológico artificial, mas também do comportamento emergente da otimização de nuvem de partículas, ou *particle swarm optimization*.

Já Tian *et al* (2006) também incrementaram o aiNet com um aprendizado elitizado para preservar anticorpos com alta afinidade aos antígenos e, diferentemente do aiNet padrão, também variam a taxa de hipermutação durante as gerações do aiNet. Neste trabalho, os autores comentam que as mudanças repercutiram na minimização de 34% no tempo de processamento e 6% de ganho de informação em relação ao aiNet padrão, em tarefas de otimização.

Buscando também a minimização de tempo de processamento e ganho de informação, neste trabalho apresenta-se três mudanças ao aiNet padrão para a tarefa de clusterização aplicada à construção de RBF. Essas mudanças ao aiNet padrão se dão através de três estratégias:

1. a construção da RBF durante as gerações do aiNet, preservando a RBF de menor taxa de erro;
2. o refinamento dos anticorpos remanescentes do processo de supressão através do algoritmo *k-means*; e
3. a divisão da matriz de memória de anticorpos do aiNet em matrizes menores, submetendo-as iterativamente ao processo de supressão.

Como elemento de comprovação de cada uma das estratégias, toma-se o problema de classificação de cromossomos humanos através de Redes Neurais com Função de Base Radial, utilizando-se as bases de dados do grupo de Copenhagen e Edimburgo (TODESCO, 1995).

Como resultado dos experimentos realizados com aiNet incrementado, destaca-se que o tempo de processamento foi minimizado em 89,91% e que o erro médio de classificação alcançado foi minimizado em 5,39%, quando comparado aos resultados alcançados pelo aiNet padrão.

Para tanto, a estrutura deste artigo, além da presente seção, apresenta os constructos Redes Neurais com Função de Base Radial, Sistemas Imunológicos Artificiais e o Algoritmo da Rede Imunológica Artificial. Também são abordadas as três estratégias propostas. Como resultados, o artigo apresenta, incrementalmente, a aplicação das estratégias propostas na construção de RBF, comentando o ganho de informação na minimização da taxa de erro de classificação e a minimização do tempo de processamento. Ao final, destacam-se as principais conclusões do trabalho.

## 2 Materiais e métodos

Nesta seção faz-se uma breve discussão a respeito de Redes Neurais Artificiais com Função de Base Radial (RBF), Sistemas Imunológicos Artificiais (SIA), Algoritmo da Rede Imunológica Artificial (aiNet) e as melhorias propostas ao aiNet.

### 2.1 RBF

As RBF são definidas na literatura como Redes Neurais Artificiais (RNA) que possuem funções de ativação radiais em sua camada intermediária. Em sua forma mais simples uma RBF é formada por três camadas de neurônios (Figura 1). A primeira camada atua como a entrada da RNA. A segunda é caracterizada como uma camada de alta dimensão, a qual promove uma transformação não-linear do espaço dimensional de entrada por meio de funções de ativação radiais em seus neurônios. E a terceira, a camada de saída, retorna a resposta da RNA, promovendo uma transformação linear do espaço de alta dimensão da camada intermediária para o espaço de baixa dimensão da saída (PANDYA, MACY, 1995).




Figura 1: Representação gráfica de uma RBF.

Uma das vantagens na utilização da RBF reside na rapidez de treinamento, sendo que este processo envolve, geralmente, duas fases distintas: um treinamento não-supervisionado e um treinamento supervisionado. Resumidamente, no treinamento não-supervisionado ocorre a formação e/ou ajustes de centróides (neurônios ou clusters) da camada intermediária. Comumente, nesta fase é empregado o algoritmo *k-means*, (TODESCO, 2006). Já no treinamento supervisionado, destinado à camada de saída, aplica-se um método que minimize uma medida de erro previamente estabelecida.

Contudo, vale ressaltar que a medida de desempenho de uma RBF está intrinsecamente ligada à determinação da camada intermediária. Neste sentido, a especificação do número ou do formato dos centróides da camada intermediária são questões empíricas tratadas durante a implementação de uma RBF.

Para contornar o empirismo relatado, trabalhos anteriores investigaram a aplicação de um algoritmo de Sistemas Imunológicos Artificiais, o aiNet, como ente responsável na determinação do número centróides e o seu posicionamento inicial em um espaço de decisão (CASTRO, ZUBEN, 2001; RAUTENBERG *et al*, 2006; e DIAO, PASSINO, 2002). Em outras palavras, o algoritmo aiNet é utilizado como um método de determinação inicial da camada intermediária de uma RBF.

## 2.2 SIA

Nasraoui *et al* (2003) comenta que organismos naturais exibem mecanismos de processamento e aprendizado poderosos, os quais habilitam os seres a sobreviver e proliferar-se por gerações em ambientes dinâmicos. Neste contexto, o sistema imunológico é um sistema de defesa importante que auxilia na própria homeostase (entendendo-se sistema por corpo), produzindo anticorpos para reconhecer e eliminar corpos estranhos como vírus e bactérias, também chamados de antígenos.

Neste enredo, entende-se que a dinâmica do sistema imunológico apresenta sinais cognitivos de inteligência (reconhecimento de antígenos) e de aprendizado (manutenção de uma comunidade de anticorpos), sendo estes sinais também estudados no campo da Inteligência Artificial (IA). Assim, recentemente, o sistema imunológico tem sido a fonte de inspiração a uma nova técnica de IA, chamada de Sistemas Imunológicos Artificiais (SIA).

Os SIA podem ser definidos como sistemas adaptativos inspirados pela teoria imunológica, funções imunológicas observáveis, princípios e modelos, que são aplicadas na resolução de problemas (TIMMIS, 2004).

Assim como em outras técnicas de IA, os SIA se respaldam no processamento dirigido sobre unidades de processamento (anticorpos), tal qual em RNA e neurônios artificiais; ou Algoritmos Genéticos e cromossomos. Biologicamente, os SIA se inspiram em algumas propriedades (DASGUPTA apud ALVES *et al*, 2004):

- O sistema imunológico pode reconhecer e classificar diferentes padrões e produzir respostas seletivas. Em adição, ele usa um processo combinatório que gera um conjunto de receptores linfócitos, com a propriedade de incrementar as chances de que ao menos alguns linfócitos reconheçam um dado antígeno.
- O sistema aprende, por experiências, a estrutura de um dado antígeno. Quando células B (na Imunologia, tipo de célula que faz o reconhecimento de antígenos) são ativadas, algumas delas se tornam células de memória, com um tempo de vida estendido. Estas células ajudam o organismo a produzir uma resposta imunológica rápida quando um mesmo antígeno é encontrado no futuro. O sistema, automaticamente, determina um balanço entre economia e desempenho, mantendo um número aproximadamente suficiente destas células B.
- O mecanismo de resposta imunológica é auto-regulado por natureza. Não há um órgão de controle no sistema imunológico. A regulação da resposta imunológica pode ser local ou sistêmica, dependendo do tipo de antígeno e sua localização.
- A resposta imunológica e a proliferação de células imunológicas ocorrem sob um determinado limiar de afinidade (a força que regula o acoplamento entre anticorpos e antígenos).
- O processo de expansão clonal e hipermutação somática produz células imunológicas com alta afinidade aos antígenos invasores.

Os SIA se valem de metáforas implementadas algoritmicamente. Dentre estas metáforas tem-se o algoritmo aiNet, o qual se caracteriza como um algoritmo auto-organizativo, onde fenômenos emergentes propiciam bons resultados à tarefas de clusterização, (CASTRO, 2001).

### 2.3 aiNet

Originalmente, o algoritmo aiNet foi proposto por Castro e Zuben e tem o propósito geral de encontrar um modelo reduzido de representação de dados pela eliminação da redundância interna de um conjunto de dados (STIBOR, TIMMIS, 2007). Em outras palavras, o objetivo do aiNet é encontrar um grafo de nodos (anticorpos) a partir de sua afinidade a uma concentração de dados (antígenos), de modo conexionista, competitivo e construtivo (CASTRO, ZUBEN, 2000). Ao final do processamento do aiNet, espera-se a definição do número ideal de anticorpos presentes na rede imunológica, assim como a distribuição espacial destes anticorpos, servindo de imagens dos *clusters* presentes em um conjunto de dados, (TSANKOVA, RANGELOVA, 2007).

De acordo com o algoritmo expresso no Quadro 1, o mecanismo de aprendizado do aiNet se vale de:

- **aleatoriedade:** é a definição de alguns anticorpos aleatórios a cada geração do aiNet, com os quais se pode explorar novos pontos no espaço de decisão.
- **afinidade:** é o grau de similaridade entre um dado anticorpo e um antígeno, ou grupo de antígenos. A afinidade é inversamente proporcional à distância anticorpo-antígeno.
- **clonagem:** é a capacidade de proliferação de anticorpos capazes de reconhecer um dado antígeno.
- **maturação/mutação:** é o aumento da afinidade entre os clones de um anticorpo e o antígeno anteriormente reconhecido. A mutação é regida por uma taxa, a qual é aumentada proporcionalmente de acordo com a distância entre o anticorpo e o outro anticorpo
- **supressão:** é a eliminação de um dos anticorpos quando identificada a similaridade entre dois anticorpos, considerando um dado limiar.

Quadro 1: Algoritmo do aiNet padrão para construção de RBF.

```
parâmetros
comprimento do antígeno
população de antígenos
número de gerações a serem executadas
número de anticorpos a serem selecionados para clonagem
percentual de anticorpos maduros a serem selecionados
limiar de morte natural
limiar de supressão
quantidade de novos anticorpos a serem inseridos na rede

início
para cada geração faça
  Crie uma pequena população de anticorpos aleatórios
  Adicione os anticorpos criados à matriz de memória de anticorpos
  para cada antígeno faça
    Determine sua afinidade em relação a todos os anticorpos
    Selecione os n anticorpos com melhores afinidades
    Clone os n anticorpos, de acordo com sua afinidade
    Submeta os clones ao processo de maturação
    Determine a afinidade dos clones ao antígeno
    Guarde os clones com melhor afinidade
    Elimine todos os clones distantes do antígeno da memória
    Determine a afinidade entre os clones da memória
    Elimine os clones de memória de acordo com limiar de supressão
    Adicione os clones restantes à matriz de memória de anticorpos
  fim para
  Determine a afinidade entre todos os anticorpos de memória
  Elimine os anticorpos de memória de acordo com limiar de supressão
fim para
Gere a RBF, tomando os anticorpos como centróides
fim.
```

Fonte: adaptado a partir de Castro (2001).

Para a construção de uma RBF, cabe ressaltar que a aplicação do algoritmo aiNet pode descaracterizar o empirismo intrínseco na determinação do número ideal de centróides (antígenos), ao mesmo tempo que sugere a localização dos centróides no espaço de decisão. A Figura 1 apresenta a visão geral da construção de uma RBF apoiada pelo aiNet.

De forma mais geral, Dasgupta (2006) aponta os SIA se constituem num ramo de investigação recente da Inteligência Artificial, por isso, a maior parte de seus estudos ainda são exploratórios. O autor salienta que pelo fato de seus algoritmos não tem boa escalabilidade, sendo que as questões ligadas ao desempenho computacional

estão em aberto. Especificamente, neste sentido, as mudanças do algoritmo aiNet proposta neste artigo vem de encontro com esta lacuna apontada.

## 2.4 Mudanças ao aiNet

As mudanças propostas neste trabalho são representadas e destacadas no Quadro 2, sendo visam melhorar a eficiência do algoritmo aiNet na construção de RBF quanto a minimização de uma medida de erro e a minimização do tempo de processamento, conforme discutido a seguir.

**Quadro 2:** Algoritmo do aiNet adaptado às mudanças propostas.

<pre>Parâmetros comprimento do antígeno população de antígenos conjunto de respostas dos antígenos população de antígenos de teste conjunto de respostas dos antígenos de teste número de subconjuntos de anticorpos a suprimir número de gerações a serem executadas número de anticorpos a serem selecionados para clonagem percentual de anticorpos maduros a serem selecionados limiar de morte natural limiar de supressão quantidade de novos anticorpos a serem inseridos na rede  início para cada geração faça   Crie uma pequena população de anticorpos aleatórios   Adicione os anticorpos criados à matriz de memória de anticorpos   para cada antígeno faça     Determine sua afinidade em relação a todos os anticorpos     Selecione os <i>n</i> anticorpos com melhores afinidades     Clone os <i>n</i> anticorpos de acordo com sua afinidade     Submeta os clones ao processo de maturação     Determine a afinidade dos clones ao antígeno     Guarde os clones com melhor afinidade     Elimine todos os clones distantes do antígeno da memória     Determine a afinidade entre os clones da memória     Elimine os clones de memória de acordo com limiar de supressão     Adicione os clones restantes à matriz de memória de anticorpos   fim para    Divida o conjunto de anticorpos em <i>n</i> subconjuntos   para cada subconjunto faça     Determine a afinidade entre todos os anticorpos de memória   (c) Elimine os anticorpos de memória de acordo com limiar de supressão     Concatene os anticorpos remanescentes ao próximo subconjunto a ser suprimido   fim para    (b) Refine os anticorpos remanescentes pelo algoritmo k-means      Gere a RBF, tomando os anticorpos como centróides e conjunto de respostas   (a) Teste a RBF gerada com os dados de teste     Se a RBF gerada obtiver a menor taxa de erro, guarde-a    fim para fim.</pre>
--

Fonte: deste trabalho.

### a) Geração Iterativa

O objetivo desta mudança é minimizar a taxa de erro previamente estabelecida. Diante do algoritmo padrão do aiNet, esta mudança repercute na construção e teste de uma RBF a cada geração do aiNet, sendo que a RBF com menor taxa de erro construída é preservada. Por isso, devem ser apresentados como parâmetros adicionais ao aiNet padrão o conjunto de respostas da população de antígenos e um conjunto de antígenos e suas respostas para a fase de teste da RBF. Salienta-se que esta estratégia foi aplicada num trabalho preliminar, onde o objetivo era demonstrar que o aiNet pode apoiar heurísticamente a procura de uma RBF adequada, e se aproximar do desempenho de dado um *benchmark*, (RAUTENBERG *et al*, 2006).

**b) Com refinamento de anticorpos**

O objetivo desta mudança também é minimizar a taxa de erro previamente estabelecida. Diante do algoritmo padrão do aiNet, esta mudança repercute no deslocamento dos anticorpos no espaço de decisão mediante a heurística do algoritmo *k-means*, melhorando a representação dos anticorpos perante os antígenos. O refinamento de anticorpos é ilustrado na Figura 2. Diferentemente da geração iterativa, nenhum parâmetro adicional necessita ser apresentado, uma vez que o *k-means* utiliza o conjunto de anticorpos remanescentes e o conjunto de antígenos, em cada geração do aiNet. Esta estratégia também foi anteriormente aplicada no trabalho de Rautenberg *et al* (2006).

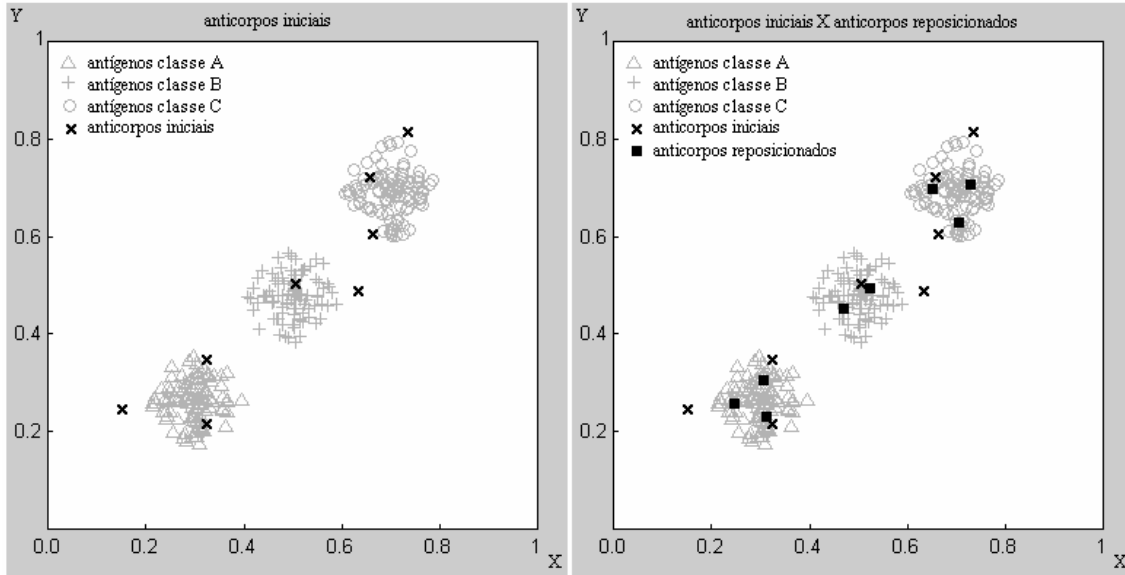


Figura 2: ilustração do reposicionamento dos anticorpos pelo algoritmo *k-means*.

**c) Com divisão da matriz de memória de anticorpos**

O objetivo desta mudança é minimizar o tempo de processamento do aiNet. Diante o algoritmo padrão, uma vez definido o conjunto da população de anticorpos candidatos, esta mudança repercute divisão da população em *n* subconjuntos, nos quais iterativamente se aplica os mecanismos de supressão. Cada subconjunto de anticorpos remanescentes é anexado ao subconjunto de anticorpos a suprimir da próxima iteração, preservando uma seletividade temporal. A explicação do porque a estratégia de divisão minimiza o tempo de processamento se dá pelo fato que na supressão, o tempo de processamento cresce exponencialmente de acordo com o aumento do número de indivíduos num conjunto a ser suprimido. Em relação ao aiNet padrão, deve ser apresentado adicionalmente o parâmetro do número de subconjuntos a serem suprimidos.

**3 Aplicação e resultados**

Para comprovar que as mudanças sugeridas repercutem na minimização do erro e na minimização do tempo de processamento na aplicação do algoritmo aiNet para construção de RBF toma-se como alicerce prático a aplicação explorada na tese de doutorado de Todesco (1995). Nesta aplicação o autor utiliza um conjunto de RBF para classificação de cromossomos humanos. As bases de dados disponibilizadas para tal, são constituídas de três características cromossômicas de entrada (o comprimento, a posição do centrômero e área do cromossomo) atreladas a um conjunto de sete classes (grupo de Denver) como padrões de saída. Conforme a Tabela 1, tais bases são segmentadas quanto à origem dos dados e aos subconjuntos de treinamento e de teste.

**Tabela 1:** Base de dados utilizada nos experimentos para treinamento e testes.

ORIGEM DOS DADOS	QUANTIDADE DE REGISTROS	
	TREINAMENTO	TESTE
Copenhagen	4061	4045
Edimburgo	2682	2866

Salienta-se também que os protótipos necessários à comprovação dos resultados são adaptados a partir de implementações de Todesco (1995) e Castro (2006). E que os experimentos foram executados em um Intel® Core Duo 2.20 Ghz e 2 Gigabytes de RAM.

Para cada experimento dos algoritmos aiNet padrão e aiNet modificado foram executados 10 testes (inicializações distintas) com 10 gerações. Foram adotados também como parâmetros:

- 5 para o número de anticorpos a serem selecionados para clonagem;
- 10% como percentual de anticorpos maduros a serem selecionados;
- 0,2 para o limiar de morte natural;
- 0,2 para a taxa de supressão; e
- 10 para a quantidade de novos anticorpos a serem inseridos na rede.

Incrementalmente, para cada base de dados, foram testados os experimentos: i) aiNet padrão e geração iterativa; ii) refinamento de anticorpos; e iii) divisão da matriz.

A Tabela 2 e a Tabela 3 ilustram o experimento aiNet padrão e geração iterativa para as bases de dados Copenhagen e Edimburgo, respectivamente. Nas tabelas, a linha da iteração 10 expressa os valores de erro alcançados pelo aiNet padrão. Já os valores destacados em cada teste, representam os valores de erro alcançados para a geração iterativa.

**Tabela 2:** taxas de erro para as RBF construídas durante a geração do aiNet padrão – Base Copenhagen.

Teste Iteração	1	2	3	4	5	6	7	8	9	10
0	59,21%	66,45%	87,37%	46,48%	85,59%	90,85%	27,56%	75,82%	73,23%	53,03%
1	5,91%	5,02%	5,19%	37,75%	5,49%	5,09%	4,92%	50,26%	5,14%	4,99%
2	4,92%	5,17%	5,09%	5,24%	4,75%	4,80%	4,80%	4,99%	5,07%	5,12%
3	5,07%	33,50%	4,97%	4,82%	4,70%	5,19%	4,87%	4,92%	4,89%	4,97%
4	5,36%	4,89%	4,92%	5,19%	4,97%	4,89%	4,89%	4,99%	4,92%	4,82%
5	4,97%	4,94%	5,04%	5,04%	4,92%	5,51%	5,09%	5,17%	4,80%	4,80%
6	4,94%	5,29%	4,75%	4,97%	5,07%	5,83%	5,14%	4,97%	4,85%	4,92%
7	4,97%	4,75%	4,99%	5,24%	4,89%	5,07%	4,70%	4,89%	5,12%	4,94%
8	4,92%	4,99%	4,85%	4,89%	4,75%	4,89%	4,77%	4,82%	4,99%	4,99%
9	5,09%	4,94%	4,97%	5,12%	4,94%	5,36%	4,94%	5,12%	4,80%	4,99%
10	4,85%	4,85%	5,36%	5,04%	5,09%	4,72%	4,87%	4,89%	4,92%	4,89%

**Tabela 3:** taxas de erro para as RBF construídas durante as geração do aiNet padrão – Base Edimburgo.

Teste iteração	1	2	3	4	5	6	7	8	9	10
0	44,35%	79,48%	67,27%	53,14%	86,85%	37,16%	66,33%	86,85%	67,76%	56,18%
1	11,34%	10,89%	11,48%	11,79%	11,44%	11,34%	11,34%	11,17%	22,19%	11,69%
2	11,55%	11,62%	11,69%	11,62%	11,27%	11,44%	11,55%	10,99%	11,65%	11,41%
3	11,76%	11,41%	11,17%	11,55%	11,69%	11,41%	11,41%	11,41%	11,27%	11,76%
4	11,31%	11,31%	11,37%	11,79%	11,62%	11,58%	11,44%	11,41%	11,37%	11,44%
5	11,27%	11,51%	11,34%	11,97%	11,31%	11,62%	11,79%	11,37%	11,34%	11,76%
6	11,34%	11,41%	11,37%	11,34%	11,69%	11,69%	11,90%	11,48%	11,62%	11,83%
7	11,86%	11,69%	11,48%	11,44%	11,10%	11,58%	11,20%	11,51%	10,85%	11,69%
8	11,13%	11,34%	11,62%	11,58%	11,37%	11,86%	11,27%	11,44%	11,79%	11,51%
9	11,65%	11,31%	11,48%	11,55%	11,72%	11,55%	11,20%	11,44%	11,83%	11,62%
10	11,58%	11,55%	11,97%	11,62%	11,31%	11,13%	11,58%	11,20%	11,34%	11,79%

Em média, a mudança “geração iterativa” em relação ao aiNet padrão, minimizou-se o erro de classificação, com um ganho de precisão na ordem de 3,65% e 3,37% para as bases de dados Copenhagen e Edimburgo, respectivamente. Isso demonstra a viabilidade desta mudança, segundo a necessidade de melhorar eficientemente os algoritmos dos SIA, (DASGUPTA, 2006), sendo esta adotada conjuntamente para as demais mudanças propostas neste trabalho.

As Tabelas 4 e 5 resumizam comparativamente os resultados para as três mudanças propostas. Comparativamente ao aiNet padrão, a mudança “refinamento de anticorpos” repercutiu num ganho de precisão, na ordem de 4,55% e 4,97%, otimizando os resultados alcançados pela “geração iterativa” e também justificando a sua adoção.

**Tabela 4:** taxas de erro, em (%), para as RBF construídas nos experimentos de aiNet – Base Copenhague.

teste experimento	1	2	3	4	5	6	7	8	9	10
aiNet padrão	4,85	4,85	5,36	5,04	5,09	4,72	4,87	4,89	4,92	4,89
geração iterativa	4,85	4,75	4,75	4,82	4,70	4,72	4,70	4,82	4,80	4,80
refinamento de anticorpos	4,75	4,72	4,67	4,65	4,82	4,67	4,72	4,77	4,80	4,67
divisão da matriz	4,70	4,60	4,65	4,75	4,77	4,67	4,62	4,72	4,70	4,77

**Tabela 5:** taxas de erro, em (%), para as RBF construídas nos experimentos de aiNet – Base Edimburgo.

teste experimento	1	2	3	4	5	6	7	8	9	10
aiNet padrão	11,58	11,55	11,97	11,62	11,31	11,13	11,58	11,20	11,34	11,79
geração iterativa	11,13	10,89	11,17	11,34	11,10	11,13	11,20	10,99	10,85	11,41
refinamento de anticorpos	10,99	10,92	10,99	11,10	10,92	11,10	10,85	11,10	10,78	10,71
divisão da matriz	10,99	10,64	11,06	10,89	10,99	10,61	10,96	10,89	10,57	10,99

A mudança “divisão da matriz”, dividindo a matriz de anticorpos candidatos ao meio, também obteve um ganho de precisão na ordem de 5,14% e 5,64%, para as bases de dados Copenhague e Edimburgo, respectivamente. Contudo, a maior contribuição desta mudança nos experimentos em relação ao aiNet padrão ocorre na minimização do tempo de processamento, o qual pode ser percebido na Tabela 6 e na Tabela 7, respectivamente, esta mudança repercutiu na minimização de 89,75% e 90,08% do tempo de processamento.


**Tabela 6:** média de tempos nas iterações (em segundos) – Experimentos Base Copenhague.

teste experimento	1	2	3	4	5	6	7	8	9	10
aiNet padrão/ geração iterativa	2443	2319	2330	2637	2524	2530	2557	2584	2454	2560
refinamento de anticorpos	2468	2450	2456	2368	2560	2495	2591	2499	2474	2535
divisão da matriz	247	267	256	260	247	260	250	263	254	253

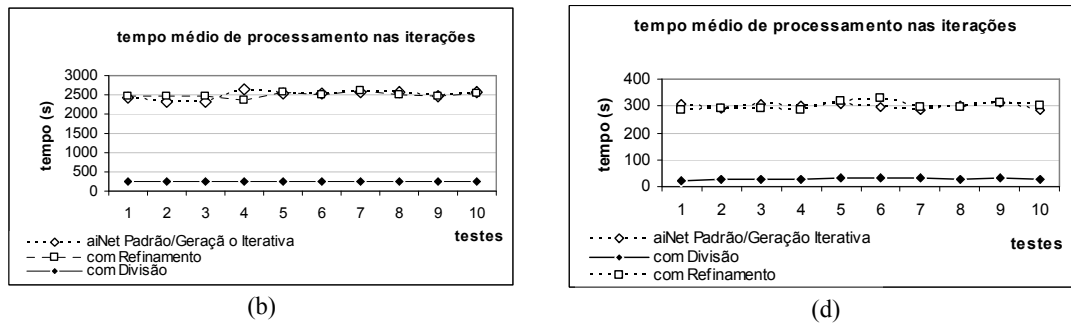
**Tabela 7:** média de tempos nas iterações (em segundos) – Experimentos Base Edimburgo.

teste experimento	1	2	3	4	5	6	7	8	9	10
aiNet padrão/ geração iterativa	305	288	309	302	306	298	287	301	312	286
refinamento de anticorpos	286	289	292	284	320	328	298	298	310	301
divisão da matriz	22	28	30	29	33	32	34	28	33	28

A Figura 3 evidencia graficamente as contribuições das mudanças em relação ao aiNet padrão.







**Figura 3:** Minimização de tempo de processamento e erro de classificação nos experimentos.

#### 4 Conclusões

Neste artigo demonstrou-se três mudanças incrementais ao algoritmo aiNet padrão, proposto por Castro e Zuben (2000) na construção de RBF. As mudanças se dão por: i) construir uma RBF durante as gerações do aiNet, preservando a RBF de menor taxa de erro; ii) refinar os anticorpos remanescentes do processo de supressão através do algoritmo *k-means*; e iii) dividir a matriz de memória de anticorpos do aiNet em matrizes menores, submetendo-as, iterativamente, ao processo de supressão. Em dois experimentos para construção de RBF para a tarefa de classificação de cromossomos humanos, estas mudanças repercutiram na minimização da taxa de erro e do tempo de processamento em 5,39% e 89,91%. Os resultados alcançados demonstram a viabilidade das mudanças e vem de encontro com os anseios de Dasgupta (2006), onde o autor afirma que uma das lacunas de investigação para os algoritmos dos SIA é a melhoria da eficiência dos algoritmos.

Com base neste trabalho, novas aplicações de grande custo computacional ao aiNet podem ser traçadas, em especial a aplicação do aiNet melhorado na diminuição do tempo de processamento em tarefas de clusterização em *datamining* e *textmining*, considerando grandes volumes de dados.

#### Referências

- ALVES, R. T. *et al.* Induction of fuzzy classification rules with an artificial immune system. In: SIMPÓSIO BRASILEIRO DE REDES NEURAIAS, 8., 2004, São Luís. *Annals...* São Luís: EEE Computer Society Press, 2004. 1 CD-ROM.
- CASTRO, L. N. *Demos manual*. Disponível em: <[http://www.dca.fee.unicamp.br/~vonzuben/research/lnunes\\_dout/software/demos/manual.htm](http://www.dca.fee.unicamp.br/~vonzuben/research/lnunes_dout/software/demos/manual.htm)>. Acesso em: 1º maio 2006.
- CASTRO, L. N. *Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais*. 2001. 286 f. Tese (Doutorado em Engenharia Elétrica)-Universidade Estadual de Campinas, Campinas, 2001.
- CASTRO, L. N.; ZUBEN, F. J. An evolutionary immune network for data clustering. In: SIMPÓSIO BRASILEIRO DE REDES NEURAIAS, 6, 2000, Rio de Janeiro. *Anais...* Rio de Janeiro: IEEE Computer Society Press, 2000. v. 1, p. 84-89.
- CASTRO, L. N.; ZUBEN, F. J. An immunological approach to initialize centers of radial basis function neural networks. In: CONGRESSO BRASILEIRO DE REDES NEURAIAS, 5, 2001, Rio de Janeiro. *Anais...* Rio de Janeiro: Sociedade Brasileira de Redes Neurais, 2001. v. 1, p. 79-84.
- DASGUPTA, D. Advances in artificial immune systems. *IEEE Computational Intelligence Magazine*, New York, v. 1, n. 4, p. 40-49, Nov. 2006.
- DIAO, Y.; PASINO, K. M. Immunity-based hybrid learning methods for approximator structure and parameter adjustment. *Engineering Applications of Artificial Intelligence*, New York, v. 15, n. 6, p. 587-600, 2002.

LI, Z. *et al.* An efficient artificial immune network with elite-learning. In: INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION, 3., 2007 Haikou. *Proceedings...* Haikou: IEEE Computer Society Press, 2007. v. 4, p 213-217.

LIU, L.; XU, W. UOFC-AINet: A fuzzy immune network for unsupervised optimal clustering. In: International. In: CONFERENCE COMPUTATIONAL INTELLIGENCE FOR MODELLING, CONTROL AND AUTOMATION, 2006, Sydney. *Proceedings...* Sydney: Computer Society Press, 2006. v. 1, p. 196.

NASAROU, O. *et al.* A scalable artificial immune system model for dynamic unsupervised learning. In: CONFERENCE ON GENETIC AND EVOLUTIONARY COMPUTATION, 2003, Chicago. *Proceedings...* Berlin: Springer, 2003. v. 2723, p. 196.

PANDYA, A. S.; MACY, R. B. *Pattern recognition with neural networks in C++*. Boca Raton: CRC Press, 1995. 432 p.

RAUTENBERG, S. *et al.* Iterative application of the ainet algorithm in the construction of a radial basis function neural network. *Learning and Nonlinear Models*, Rio de Janeiro, v. 4, n. 1, p. 24-31, 2006.

STIBOR, T.; TIMMIS, J. An investigation on the compression quality of aiNet. In: IEEE SYMPOSIUM ON FOUNDATIONS OF COMPUTATIONAL INTELLIGENCE, 2007, Honolulu. *Proceedings...* Honolulu: IEEE Computer Society Press, 2007. v. 1, p 495-502.

TIAN, X. *et al.* A novel artificial immune network algorithm. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS, 5., 2006, Dalian. *Proceedings...* Dalian: IEEE Computer Society Press, 2006. v. 1, p 2159-2165.

TIMMIS, J. Exploiting the immune system for computation. *IEEE Intelligent Informatics Bulletin*, New York, v. 4, n. 2, p. 1-2, Dec. 2004.

TODESCO, J. L. *Reconhecimento de padrões usando rede neuronal artificial com uma função de base radial: uma aplicação na classificação de cromossomos humanos*. 1995. 105 f. Tese (Doutorado em Engenharia de Produção)-Universidade Federal de Santa Catarina, Florianópolis, 1995.

TSANKOVA, D.; RANGELOVA, V. Modeling cancer outcome prediction by aiNet: discrete artificial immune network. In: MEDITERRANEAN CONFERENCE ON CONTROL & AUTOMATION, 2007, Athens. *Proceedings...* Athens: IEEE Computer Society Press, 2007. v. 1. p 1-6.

## **SOBRE OS AUTORES**

### **Sandro Rautenberg**

Possui graduação em Ciências da Computação pela Universidade Regional de Blumenau – FURB (1996), mestrado em Engenharia de Produção pela Universidade Federal de Santa Catarina – UFSC (1998). Atualmente é professor assistente junto ao Departamento de Ciência da Computação da Universidade Estadual do Centro-Oeste (UNICENTRO) e doutorando no Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento da UFSC. Tem experiência em Inteligência Artificial e Engenharia do Conhecimento.

### **José Leomar Todesco**

Possui graduação em Matemática pela Universidade Federal de Santa Catarina - UFSC (1987), mestrado e doutorado em Engenharia de Produção também pela UFSC (1991 e 1995, respectivamente). Atualmente ocupa o posto de professor adjunto junto ao departamento de Informática e Estatística (INE) na graduação e no Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento da UFSC e como pesquisador do Instituto Stela. Tem experiência na área de Ciência da Computação, com ênfase em Data Warehouse, Inteligência Artificial e Engenharia do Conhecimento.