

APLICAÇÃO ITERATIVA DO ALGORITMO aiNET DE SISTEMAS IMUNOLÓGICOS ARTIFICIAIS NA CONSTRUÇÃO DE UMA REDE NEURAL COM FUNÇÃO DE BASE RADIAL

SANDRO RAUTENBERG^{1,3}, LUCIANO F. DE MEDEIROS^{2,3}, WAGNER IGARASHI³, JOSÉ, L. TODESCO³, FERNANDO O. GAUTHIER³, ROGÉRIO C. BASTOS³

¹UNICENTRO - Universidade Estadual do Centro-Oeste

²Grupo Educacional UNINTER - Curitiba - PR - Brasil

³Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento, UFSC

Endereço para Correspondência - Caixa Postal 476 - 88040-900 - Florianópolis - SC - Brasil

E-mail: srautenberg@unicentro.br, lfm@egc.ufsc.br, igarashi@stela.org.br, tite@egc.ufsc.br, gauthier@inf.ufsc.br, rogerio@inf.ufsc.br

Abstract— This article presents some adopted procedures to build a Radial Basis Function Neural Network by iteratively applying the aiNET, an Artificial Immune Systems Algorithm. Such solution has shown effectiveness taking into account two factors: i) the free determination of centroids inspired by an immune heuristic; and ii) the achievement of appropriate minimal square errors after a number of iterations. Experimental and empirical results are compared aiming to confirm some hypothesis.

Keywords— Artificial Immune Systems, Radial Basis Function Neural Network, aiNET.

Resumo— Este artigo expõe os procedimentos adotados na construção de uma Rede Neural Artificial com Função de Base Radial (RBF) ideal por meio da aplicação iterativa do algoritmo aiNet de Sistemas Imunológicos Artificiais. Esta solução mostrou-se eficaz sob duas óticas: i) a determinação livre de um arranjo de centróides, por uma heurística imunologicamente inspirada; e ii) o encontro de erros quadráticos mínimos satisfatórios, considerando algumas iterações. Resultados experimentais são mostrados e comparados a resultados empíricos que confirmam as considerações.

Palavras-chave— Sistemas Imunológicos Artificiais, Rede Neural com Função de Base Radial, aiNET.

1 Introdução

Nos anos oitenta e noventa alguns estudos de Inteligência Artificial (IA) se voltaram para a criação e utilização de Sistemas Híbridos Inteligentes. Tais sistemas eram respaldados em duas ou mais técnicas de IA, sob o pretexto de melhorar resultados ou transpor limitações de uma técnica de IA em particular. Exemplificando, Algoritmos Genéticos (AG) foram empregados na especificação de arquiteturas iniciais de Redes Neurais Artificiais (RNA); Sistemas Especialistas (SE) foram empregados como entes de justificação de respostas de RNA; Conjuntos Difusos foram empregados no tratamento de incertezas em SE; entre outras formas de hibridização.

Outro fato recente e que merece menção é o surgimento de uma nova técnica de IA denominada Sistemas Imunológicos Artificiais (SIA). Resumidamente, os SIA são uma técnica da IA que captura aspectos biológicos do sistema imunológico, implementando metáforas nele inspiradas, que por sua vez podem ser aplicadas em diversas áreas como reconhecimento de padrões, segurança computacional, robótica, otimização, controle, aprendizagem de máquina, análise de dados, entre outras, [Silva, 2001]. Dasgupta, em artigo seminal, já comparava os SIA com as RNA [Dasgupta, 1997]. Citam-se também alguns modelos híbridos abrangendo SIA e Mapas Auto-Organizáveis (Self-Organizing Maps-SOM) [Feyereisl and Aickelin, 2006].

Em se tratando de Redes Neurais Artificiais (RNA), vale ressaltar dois pontos cruciais, os quais podem ocasionar tarefas exaustivas na construção de soluções baseadas nesta tecnologia. O primeiro ponto se refere à busca empírica do projetista envolvido na tarefa de construção, com a intenção de encontrar os parâmetros ideais de configuração. O segundo é a casualidade pela determinação inicial (geralmente aleatória) dos pesos nas ligações sinápticas.

Pontualmente, este trabalho trata a construção de RNA com função de base radial (Radial Basis Function), conhecidas como RBF. Embora este modelo de RNA possa ter seus pesos determinados a partir dos dados de treinamento, eliminando o aspecto da casualidade, este processo ainda possui certo grau de empirismo. Neste sentido, a busca do número ideal de neurônios na camada intermediária e a distribuição destes neurônios num espaço de decisão são determinantes na medida de desempenho de uma RBF. Para esta necessidade, buscar amparo em outras tecnologias é, sem dúvida, uma tarefa de grande valia.

Assim, este artigo tem o objetivo de mostrar, numa aplicação específica, o acoplamento entre os dois paradigmas, RBF e SIA, e buscar no modelo híbrido a melhoria de desempenho da tarefa de classificação aqui abordada. A estrutura do artigo começa com uma fundamentação teórica sobre os paradigmas e a metodologia empregada na aplicação. Logo após, apresentam-se os resultados e comparações e, ao final, tem-se a conclusão do trabalho.




Figura 1. Representação gráfica de uma RBF.

2 Referencial teórico

2.1 Redes Neurais Artificiais com Função de Base Radial (RBF)

As RBF são definidas na literatura como RNAs 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, 1995].

Uma das vantagens na utilização de 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 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 pelo projetista durante a implementação de uma RBF.

Para contornar o empirismo relatado, este trabalho investiga a aplicação de um algoritmo de Sistemas Imunológicos Artificiais, o aiNet (Artificial Immune Network), como ente responsável na determinação do número centróides e o seu posicionamento inicial em um hiperplano de decisão. Em outras palavras, o algoritmo aiNet é utilizado como um método de determinação inicial da camada intermediária de uma RBF. Ressalta-se que Silva & Zuben (2001)

e Diao & Passino (2002) pesquisaram este princípio, mas não de forma iterativa.

2.2 Sistemas Imunológicos Artificiais

Para Nasraoui et al (2003), 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), reconhecendo e eliminando corpos estranhos (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 IA. Assim, recentemente, o sistema imunológico humano tem sido a fonte de inspiração a uma nova técnica de IA, chamada de Sistemas Imunológicos Artificiais (SIA). Historicamente, segundo Silva & Zuben (2006), o trabalho precursor de SIA foi “The Immune Systems, Adaptation, and Machine Learning”, por Farmer, Packard e Perelson [Farmer et al, 1986].

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, SIA se respaldam no processamento dirigido sobre unidades de processamento (anticorpos), tal qual em RNA e neurônios artificiais; ou AG e cromossomos. Biologicamente, SIA se valem de 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 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.

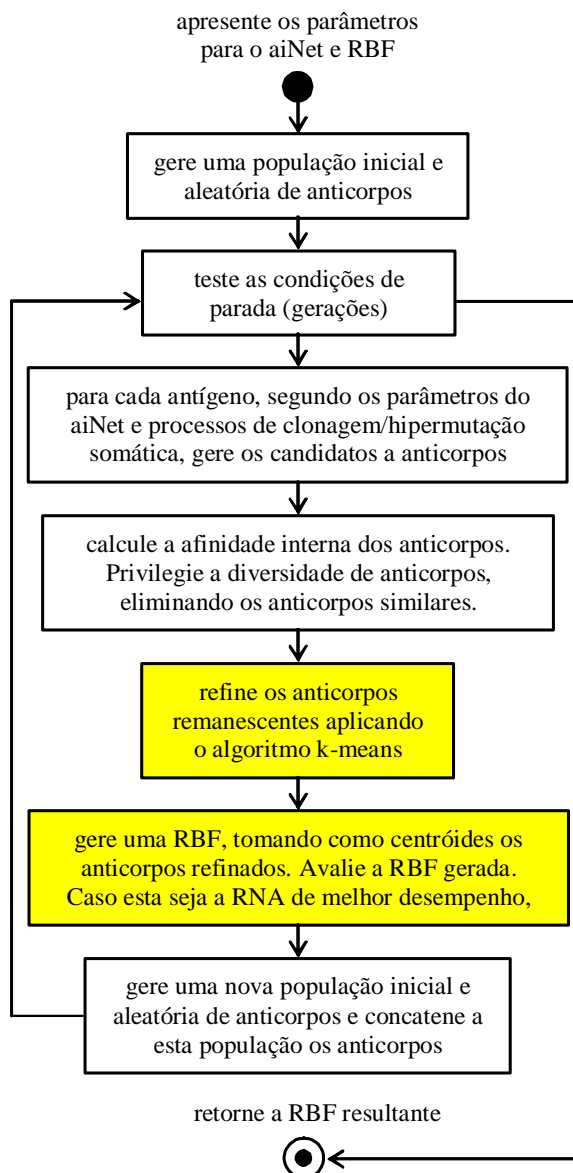


Figura 2. Representação gráfica do aiNet adaptado a proposta do trabalho.

- 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 produzem células imunológicas com alta afinidade aos antígenos invasores. Vale ressaltar que a expansão clonal e a hipermutação somática são aspectos fortemente explorados no algoritmo aiNet.

O processamento dirigido de um SIA, então, se dá por meio de metáforas implementadas algoritmicamente. Dentre alguns algoritmos, destacam-se o

aiNet (Artificial Immune NETWORK) e o CLONALG (CLONal selection ALGORITHM), os quais são aplicados combinadamente em tarefas de aprendizagem de máquina, reconhecimento de padrões, compressão e *clustering*, [Silva, 2001]. O aiNet tem sua dinâmica iniciada com o fornecimento dos antígenos (padrões de treinamento) e demais parâmetros. A cada iteração (geração), na aplicação do algoritmo de seleção clonal, são produzidos os anticorpos (centróides) que se acoplam (representam) a um grupo de antígenos (dados a serem aglomerados). Disto, a cada geração, os anticorpos (que inicialmente são representações aleatórias) são refinados e/ou criados.

Para o projeto de uma RBF, cabe ressaltar que a aplicação do algoritmo aiNet pode descaracterizar o empirismo do projetista na determinação do número ideal de centróides, ao mesmo tempo que sugere a localização inicial de cada um. Na próxima seção, informações adicionais são acrescentadas, sendo o foco central a discussão da integração iterativa do algoritmo aiNet no projeto de uma RBF.

2.3 O método de construção de RBF aplicado

O método de construção aplicado neste trabalho consiste em 5 (cinco) passos:

- Os padrões de entrada e saída são apresentados ao algoritmo aiNet, juntamente com demais parâmetros;
- O algoritmo aiNet define um conjunto de centróides inicial (conjunto de anticorpos) para uma RBF;
- Os centróides iniciais são refinados pelo algoritmo k-means, resultando num conjunto de anticorpos “mais afinados” à solução do problema;
- Os padrões de saída e os centróides são utilizados na geração de uma RBF;
- A RBF gerada é testada com a apresentação de novos padrões de entrada e de saída, sendo que a medida de erro aferida é a determinante à retenção da melhor RNA como solução.

Salienta-se que os passos dois a cinco são realizados de forma iterativa, de acordo com o parâmetro de épocas utilizado no algoritmo aiNet. Figura 2 evidencia, em amarelo, a adaptação iterativa, em relação aos estudos de Silva & Zuben (2001) e Diao & Passino (2002).

A constatação de que este é um método válido de construção de RBF se deve por duas assertivas:

- O refinamento do conjunto de anticorpos ou centróides em relação aos centros de massa dos dados de treinamento (aplicação do k-means) tem melhor representatividade para a população dos exemplos (antígenos). Subsequentemente, isto garante maior minimização do erro. A Figura 3 ilustra esta assertiva.
- Uma minimização ótima do erro pode surgir durante as iterações do algoritmo aiNet, onde é

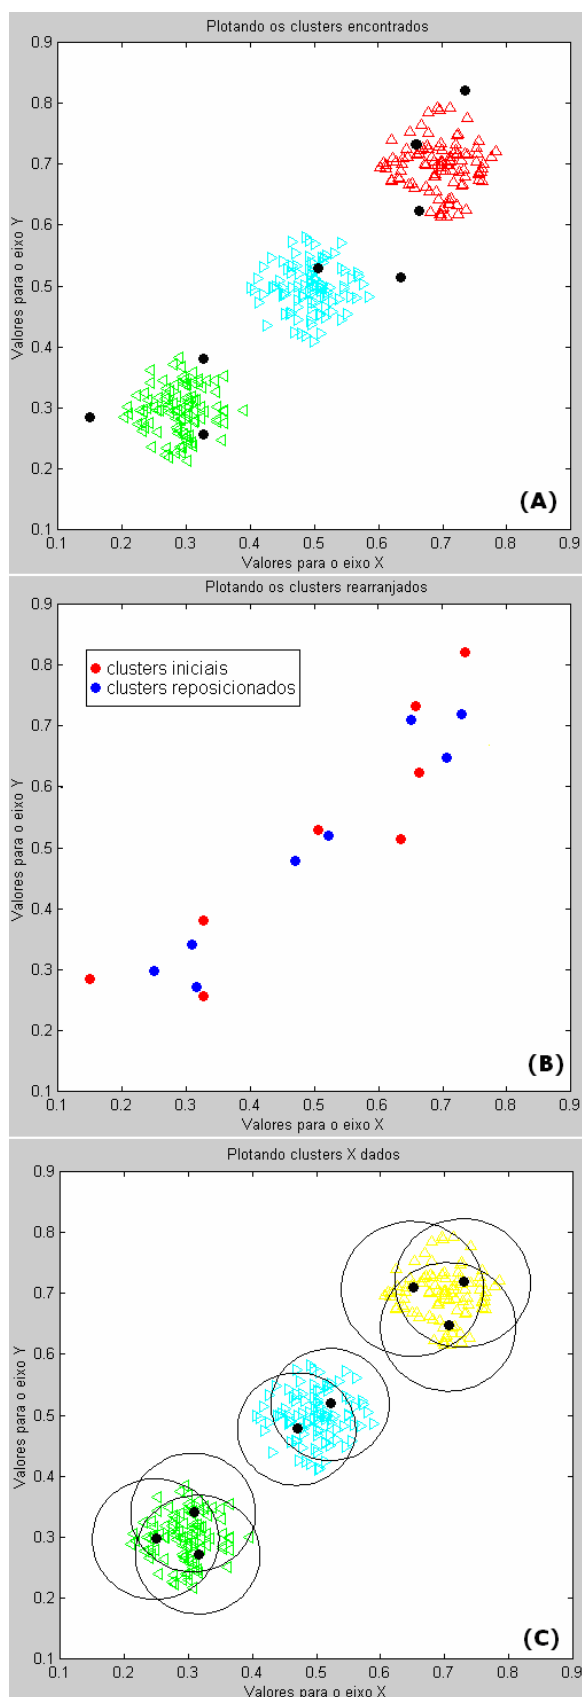


Figura 3. Passos da proposta.

definido o número ótimo de centróides (veja a seção 5 Resultados).

Destaca-se que os protótipos necessários ao método de construção de RBF sugerido são adaptados a

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

| ORIGEM DOS DADOS | QUANTIDADE DE REGISTROS | |
|------------------|-------------------------|--------|
| | TREINO | TESTES |
| Copenhagen | 4061 | 4045 |
| Edinburgo | 2682 | 2866 |

partir de implementações [Todesco, 1995] e [Silva, 2006].

3 Aplicação e Resultados

A aplicação sugerida como alicerce prático advém da tese de doutorado de Todesco (1995), onde o autor utiliza um conjunto de RBF para classificação de cromossomos humanos. As bases de dados são constituídas de três características cromossômicas de entrada (o comprimento, a posição do centrômero e área do cromossomo) e ao conjunto de sete classes (grupo de Denver) como padrões de saída. Conforme a Tabela 1, tais bases são segmentadas quanto a origem dos dados, treino e testes.

Há de se ressaltar que, quando da utilização dos dados para todas as fases de treinamento, somente são considerados os 1.000 (mil) primeiros registros de treinamento. Em se tratando da fase de testes, todos os registros são considerados.

A Tabela 2 sumariza os testes realizados para a proposta de construção empregada. Nota-se, portanto, que o método se mostra promissor em encontrar taxas de erro minimizadas, sendo que o método também descarta a tarefa (para o projetista de RBF) de especificar o número ideal de centróides. Neste sentido, para o experimento com dados de Copenhagen, o método encontrou 61 centróides para a RBF de melhor desempenho durante o processo iterativo de construção. Já para o experimento com dados de Edinburgo, 66 foi o número ideal de centróides.

Para melhor visualização dos resultados, a partir da Figura 4 verifica-se a evolução do método em relação às iterações, considerando o número de centróides formados e as taxas de erro. É importante destacar na figura que a RBF de melhor desempenho é alcançada em iterações intermediárias do aiNet.

4 Conclusão

A partir dos resultados obtidos no modelo híbrido aiNet-RBF aqui descrito, algumas vantagens podem ser evidenciadas. Uma delas é a descaracterização do empirismo na determinação dos centros das funções de base radial por meio de uma metodologia bem definida pelo uso do operador aiNet. Outra vantagem é a redução do conjunto de amostras para a determinação destes centros, facilitando a tarefa para o algoritmo k-means, sem parametrização adicional. Uma análise que pode merecer atenção futura é o

Tabela 2. Comparativo do método proposto à construção tradicional de RBF por kmeans.

| origem dos dados | QUADRO COMPARTATIVO (porcentagem de erro) | | | Proposta |
|------------------|--|-------|-------|----------|
| | RBF treinada com algoritmo <i>k-means</i> | | | |
| | Número de centróides testados empiricamente | | | |
| | 50 | 75 | 100 | |
| Copenhagen | 5,40 | 5,44 | 5,36 | 5,33 |
| Edinburgo | 11,55 | 11,48 | 12,25 | 11,58 |

impacto do número de dimensões do espaço de entrada, pois havendo redução do número de amostras, a complexidade de tempo e espaço pode ser minimizada.

A comparação entre o modelo básico RBF e *k-means* e o modelo híbrido RBF / *k-means* / aiNet foi mensurada por meio do erro de classificação. A comparação pode ser estendida em trabalhos futuros, e outros indicadores podem ser adotados para uma abordagem ampla de avaliação, tais como a validação cruzada generalizada (Generalized Cross Validation - GCV) e critério de inferência bayesiana (Bayesian Inference Criterion). Além da base de cromossomos humanos considerada neste trabalho, outras bases de uso comum podem ser usadas para testar tarefas de classificação pelo modelo híbrido.

Outros modelos de RNA podem ser utilizados para compor um modelo híbrido com SIA, tais como o Perceptron Multicamada (Multi-Layer Perceptron - MLP). Ainda que se tenha alcançado uma metodologia para determinar os centros das funções de base radial, ainda fica em aberto a questão do raio ou variância, e isto é ressaltado como oportunidade à continuidade da pesquisa do modelo híbrido RNA-SIA aqui concebido.

Referências Bibliográficas

- Alves, R. T, et al. (2004). Induction of Fuzzy Classification Rules with an Artificial Immune System, *Proceedings of SBRN - 8th Brazilian Symposium on Neural Networks*, CD_ROM.
- Dasgupta, D. (1997). Artificial Neural Networks and Artificial Immune Systems: Similarities and Differences, *Proceedings of the IEEE SMC*, 1, p. 873-878.
- Diao, Y; Pasino, K, M. (2002). Immunity-based hybrid learning methods for approximator structure and parameter adjustment. *Engineering Applications of Artificial Intelligence*, v. 15, n. 6, p. 587-600.
- Farmer, J. D., Packard, N e Perelson, A. (1986) The immune system, adaptation and machine learning, *Physica D*, v. 2, p. 187-204.
- Feyereisl, J. and Aickelin, U. (2006). Artificial Immune Tissue using Self-Organizing Networks, *Proceedings of the Workshop on*

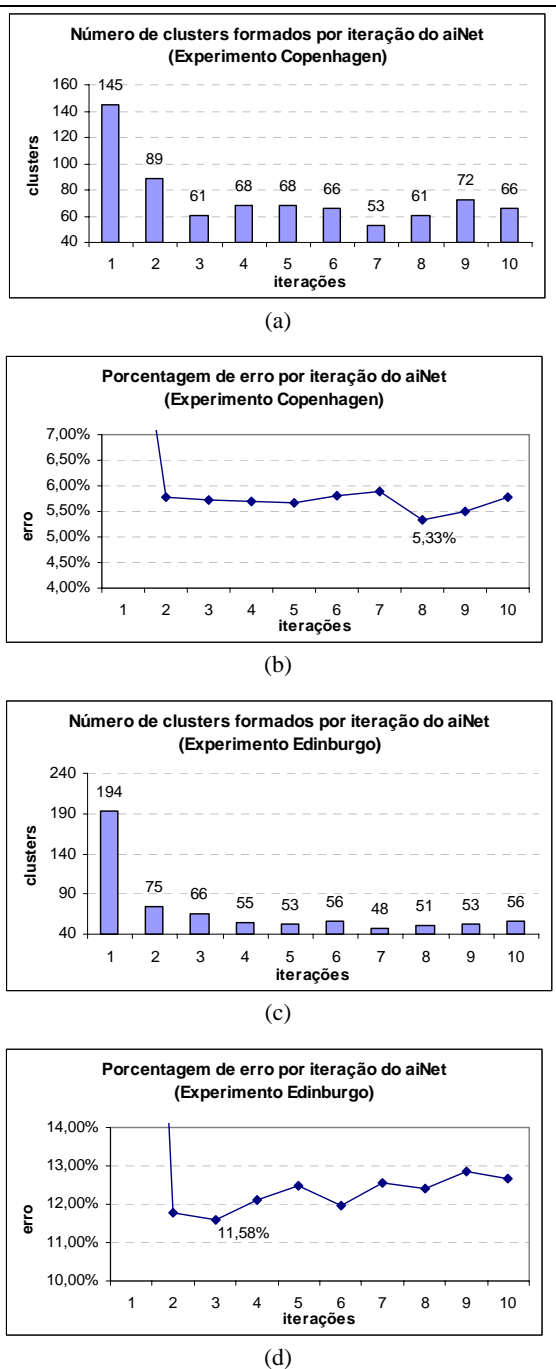


Figura 4. Resumo da evolução das iterações para os experimentos.

Artificial Immune Systems and Immune System Modelling, p 5-6.

Nasaroui, O., et al. (2003). A Scalable Artificial Immune System Model for Dynamic Unsupervised Learning, *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO)*, p. 219-230.

Pandya, A. S. (1995). *Pattern recognition with neural networks in C++*, CRC Press.

Silva, L. N. de C. (2006). Demo Manual. Disponível em:

<http://www.dca.fee.unicamp.br/~vonzuben/research/lnunes_dout/software/demos/manual.htm>

. Acesso em 1, Maio.

- Silva, L. N. de C and Zuben, F. J. von (2001). An Immunological Approach to Initialize Centers of Radial Basis Function Neural Networks, Proceedings of CBRN 2001 - V *Brazilian Conference on Neural Networks*, p. 79-84.
- Silva, L. N. de C, ZUBEN, F. J. von (2006). Artificial Immune Systems: Part II – a Survey of Application. Disponível em: <http://www.dca.fee.unicamp.br/~vonzuben/research/lnunes_dout/relatorios/rtdca0200.pdf>. Acesso em 5, Maio.
- Silva, L. N. de C. (2001). Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais inspiradas em Sistemas Imunológicos Artificiais, Tese (doutorado) - *Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, Campinas*.
- Timmis, J (2004). Exploiting the Immune System for Computation, *IEEE Intelligent Informatics Bulletin*, Vol. 4 n. 2, p. 1-2.
- Todesco, J. L. (2006). Introdução à Inteligência Aplicada – Redes Neurais. Disponível em: <<http://www.inf.ufsc.br/~tite/IA/Aula6/RedesNeurais.pdf>>. Acesso em 5, Maio.
- Todesco, J. L. (1997). Reconhecimento de padrões usando rede neuronal artificial com uma função de base radial: uma aplicação na classificação de cromossomos humanos, *Tese (Doutorado em Engenharia de Produção) - Engenharia de Produção e Sistemas, UFSC, Florianópolis*.