

Método AGCRN-CR para Busca Automática de Redes Neurais Artificiais

Anderson Paulo da Silva¹, Teresa B. Ludermir¹, Leandro M. Almeida¹

¹Centro de Informática – Universidade Federal de Pernambuco (UFPE)
Caixa Postal 50740-560 – Recife– PE – Brasil

{aps3,tbl, lma}@cin.ufpe.br

Abstract. *This paper describes an automatic search method, CGANN-DC (Cellular Genetic Algorithm + Neural Networks - Direct enCod), for Artificial Neural Networks (ANNs) using Cellular Genetic Algorithms (CGAs). The main difference between CGAs and Genetic Algorithms (GAs) is the use of a cellular automaton (CA) capable of providing the location for individuals, reducing the possibility of local minima in search space. The CGANN-DC performs evolutionary searches for initial weights, transfer functions, architectures and learning rules. Experimental results have shown that the CGANN-DC can find compact networks with a satisfactory generalization power.*

Resumo. *Este artigo descreve um método de busca automática, AGCRN-CR (Algoritmo Genético Celular + Rede Neural - Codificação Real), por Redes Neurais Artificiais (RNAs) utilizando Algoritmos Genéticos Celulares (AGCs). A principal diferença entre AGCs e Algoritmos Genéticos (AGs) é o uso de um autômato celular (AC) para dar localização aos indivíduos, reduzindo as chances destes caírem em mínimos locais no espaço de busca. O AGCRN-CR executa buscas evolucionárias por pesos iniciais, funções de transferência, arquiteturas e regras de aprendizado. Resultados experimentais mostram que o AGCRN-CR pode encontrar redes compactas com satisfatório poder de generalização.*

1. Introdução

A busca por redes neurais artificiais (RNAs) que se adéquem a determinados problemas é vista como uma questão importante na aplicação de RNAs, uma vez que o poder de generalização de uma rede neural pode ser melhorado de acordo com a devida escolha dos seus parâmetros. Tal busca possui uma série de dificuldades, visto que a construção de uma RNA com configuração que se aproxime do ótimo envolve questões como o exponencial número de parâmetros que precisam ser ajustados, a necessidade do conhecimento *a priori* do domínio do problema e do funcionamento da RNA para definição destes problemas, além da necessidade de um especialista quando este conhecimento não existe [Almeida and Ludermir, 2007]. Essa busca por uma configuração de RNA adequada, de forma geral, é feita manualmente ou através de métodos de busca que consigam encontrar configurações ótimas ou se aproximem do ótimo. Nesse contexto, alguns pesquisadores propõem métodos de busca evolucionária que visam “evoluir” as soluções do problema em questão a partir de uma solução inicial (ou conjunto de soluções iniciais) [Abraham, 2004. Pedrajas, et al. 2005].

Neste trabalho, apresentamos um método de busca que utiliza RNAs e um tipo diferente de AG, conhecido como Algoritmo Genético Celular (AGC) com codificação

real. Este método é denominado AGCRN-CR (Algoritmo Genético Celular + Rede Neural - Codificação Real), e baseia-se no método proposto por [Almeida and Ludermir, 2007] denominado NNGA-DCOD (aNN + GA – Direct enCODe). O NNGA-DCOD faz busca por pesos iniciais, arquiteturas, funções de ativação e regras de aprendizagem para rede neural através de um AG comum e visa encontrar redes compactas com bom poder de generalização. A principal diferença do AGCRN-CR em relação ao NNGA-DCOD é o tipo de algoritmo genético utilizado, onde um Autômato Celular (AC) trabalha em conjunto com um AG, dando localidade aos elementos, formando o AGC. Este trabalho está dividido da seguinte forma: A seção 2 apresenta os conceitos básicos de algoritmos genéticos e sua utilização com RNAs; Seção 3 os conceitos de algoritmos evolucionários celulares; Seção 4 descreve o método AGCRN-CR; Seção 5 descreve os resultados experimentais; Seção 6 descreve as conclusões e apresenta os trabalhos futuros.

2. Algoritmos Genéticos e Redes Neurais Evolucionárias (RNAEs)

Os AGs são técnicas evolucionárias que visam achar soluções ótimas ou quase-ótimas em problemas de otimização e busca. Através da união de técnicas evolucionárias (entre elas AGs) e RNAs na busca dos próprios componentes das RNAs, temos as redes neurais artificiais evolucionárias (RNAEs), que foram definidas por [Yao, 1999]. As RNAEs conseguem ter um melhor aproveitamento (*exploitation*) e exploração (*exploration*) de grande número de aspectos e componentes necessários (como pesos, arquiteturas e funções de transição) para a construção de RNAs com bom poder de generalização.

Mesmo trazendo, em geral, bons resultados, um dos problemas mais comuns na utilização de AGs é a convergência da busca dentro de um ponto de mínimo local no espaço de pesquisa, uma vez que a evolução dos indivíduos sem o correto controle pode gerar a produção de super indivíduos que possuem sempre a mesma carga genética (ou uma carga genética muito parecida) e que irão predominar em relação a todos os outros, reduzindo as chances de encontrar a solução ideal, ou até mesmo soluções diferentes, pois a diversidade genética é essencial para que o AG encontre as soluções ideais [Almeida and Ludermir, 2007].

Ainda assim, diversos pesquisadores têm empregado os algoritmos genéticos com sucesso em suas pesquisas [Yao, 1999. Almeida, 2007]. Dentro das pesquisas, foi possível perceber que apesar de possuírem resultados relevantes, as principais desvantagens dos AGs são as perturbações de boas sub-soluções pelas operações de cruzamento e mutação, além da perda da diversidade genética causada pelo operador de seleção, que constantemente diminui a variedade dos cromossomos [Rajabalipour, et al. 2009].

3. Algoritmos Evolucionários Celulares

Uma das formas encontradas para amenizar as perturbações das sub-soluções causadas pelos operadores dos AGs foi proposta por [Cao and Wu, 1998], onde os pesquisadores introduziram autômatos celulares (ACs) para realizar a localização e vizinhança na estrutura da população dos algoritmos genéticos. Um AC é um modelo discreto estudado na teoria da computabilidade, matemática e biologia teórica. Consiste de uma grelha finita e regular de células, cada uma podendo estar em um número finito de estados, que variam de acordo com regras determinísticas. A grelha pode ser em

qualquer número finito de dimensões. O tempo também é discreto e o estado de cada célula no tempo t é uma função do estado no tempo $t-1$ de um número finito de células na sua vizinhança. Essa vizinhança corresponde a uma determinada seleção de células próximas (podendo eventualmente incluir a própria célula). Todas as células evoluem segundo a mesma regra de atualização, baseada nos valores de suas células vizinhas. Cada vez que as regras são aplicadas à grelha completa, uma nova geração é produzida. Os autômatos celulares foram introduzidos por Von Neumann e Ulam [Wolfram, 2002] como modelos para estudar processos de crescimento e auto-reprodução. Qualquer sistema com muitos elementos idênticos que interagem local e deterministicamente podem ser modelados usando autômatos celulares.

Assim, a saída encontrada em [Cao and Wu, 1998] foi controlar a seleção com base no grid do AC para evitar a perda rápida da diversidade durante a pesquisa genética, baseando-se na distribuição paralela das populações, onde a idéia de isolar os indivíduos possibilita grande diferenciação genética [Wright, 1943]. Em alguns casos [Alba and Troya, 2002], estes algoritmos utilizando populações descentralizadas conseguem prover uma melhor amostragem do espaço de busca e também melhorar o tempo de execução. Da combinação entre AGs e ACs surgiu o algoritmo genético celular (AGC), que, por sua vez, pertence a um subconjunto dos algoritmos evolucionários chamados de algoritmos evolucionários celulares (AEC).

Nos AECs o conceito de vizinhança é muito utilizado, de modo que um indivíduo interage apenas com seus vizinhos mais próximos. Através desta restrição de interação, os AECs conseguem melhorar o comportamento numérico do algoritmo pela estruturação da população, conseguindo, em geral, melhores taxas e tempos de execução [Alba and Dorronsoro, 2008].

O modelo celular simula a evolução natural do ponto de vista do indivíduo. A principal idéia deste modelo é dar à população uma estrutura especial definida como um grafo conectado, no qual cada vértice é um indivíduo que se comunica com os seus vizinhos mais próximos. Ao visualizar a população de AGs desta forma, podemos dizer que em um AG comum, sua população estaria como um grafo completamente conectado, onde os vértices são os indivíduos e as arestas as suas relações, enquanto num AG celular as interações acontecem apenas com os vizinhos mais próximos como um grafo de estrutura, difundindo lentamente as soluções e mantendo a diversidade mesmo entre os vizinhos próximos. A figura 1 mostra estes grafos [Alba and Dorronsoro, 2008].

Os AGCs são uma subclasse dos algoritmos evolucionários no qual a população é distribuída num grid bidimensional toroidal [Simoncini, et al. 2007]. Além de possuírem todos os conceitos de um AG comum, os AGCs incrementam ao seu processo evolutivo um autômato celular.



Figura 1. Grafo completamente conectado e grafo de estrutura

Cada célula do AC possui um indivíduo do AG e os operadores genéticos (seleção, reprodução e mutação) são aplicados na vizinhança de um determinado cromossomo escolhido no grid. Como dito anteriormente, a evolução natural aqui se faz voltada para o ponto de vista do indivíduo, ou seja, só há cruzamento entre aqueles indivíduos mais próximos, simulando a influência entre os indivíduos numa sociedade. As interações da população dependem de sua topologia de vizinhança. A figura 2 mostra os dois tipos de vizinhança mais encontrados na literatura, a vizinhança de Neumann e a vizinhança de Moore.



Figura 2. Tipos de Vizinhanças

4. O método AGCRN-CR

O desenvolvimento do AGCRN-CR utiliza RNAs Evolucionárias (RNAEs). A busca evolucionária é subdividida em camadas, onde cada camada possui uma determinada informação da RNA a ser “evoluída” por um AGC específico que trabalha com a informação pertinente à camada em questão. O uso do AGC visa escapar dos mínimos locais e encontrar redes com melhores configurações em relação a um AG comum (assim como o NNGA-DCOD). Essa pesquisa é feita da seguinte forma:

- Na camada mais baixa é feita a busca evolucionária por pesos iniciais da RNA;
- Na camada intermediária ocorre a busca evolucionária por arquiteturas e funções de ativação. Nesta busca também são incluídos o número de camadas escondidas e o número de neurônios por camada;
- Na camada superior a busca evolucionária por regras de aprendizagem (parâmetros dos algoritmos de treinamento) é feita.

A figura 3 mostra uma possível configuração de busca.

Como é possível perceber de acordo com a figura 3, a velocidade de evolução é maior na camada inferior (busca por pesos iniciais), pois neste ambiente o número de arquiteturas e regras de aprendizado é previamente delimitado. Esse formato foi adotado por [Abraham, 2004] onde são feitas buscas mais extensas por arquiteturas e pesos iniciais, tendo as regras de aprendizagem parcialmente definidas.

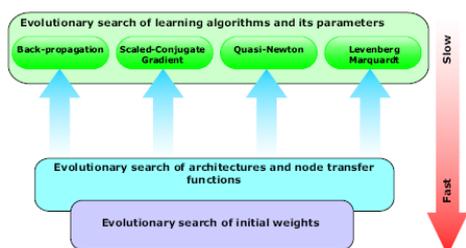


Figura 3. Busca evolucionária em camadas

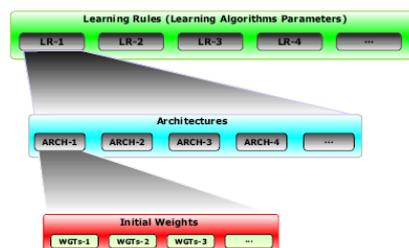


Figura 4. Composição dos dados na busca evolutiva

O AGCRN-CR realiza a busca por RNAs totalmente conectadas com aprendizado supervisionado para problemas de classificação que têm uma arquitetura simples (com poucas camadas ocultas e até 12 nodos por camada), convergência mais rápida com poucas épocas de treinamento e satisfatória performance de generalização. Por exemplo, no trabalho de Ajit Abraham [Abraham, 2004] são usadas até 500 épocas de treinamento para cada rede, enquanto o método AGCRN-CR utiliza até 5 épocas. A composição dos dados na busca evolutiva em camadas do AGCRN-CR é mostrada na figura 4, onde cada camada trabalha com uma população diferente de indivíduos que irá codificar um atributo em questão das RNAs. Na camada inferior há a população de pesos iniciais (PPI), na camada intermediária há a população de arquiteturas e funções de ativação (PAF) e na camada superior há a população de regras de aprendizado (PRA). Como já citado anteriormente, cada uma dessas populações trabalha com os valores reais específicos aos seus domínios de problema, ou seja, a PPI possui populações de cromossomos com os dados reais dos pesos das redes neurais, a PAF populações com os dados reais de configuração de arquiteturas e funções de ativação aplicadas e a PRA possui populações com os dados reais dos parâmetros dos algoritmos de aprendizagem aplicados.

Uma vez que os dados reais são utilizados, o processo de codificação e decodificação dos cromossomos é dispensado, mas é preciso adaptar os operadores genéticos para funcionarem com tal tipo de codificação. Estes operadores foram desenvolvidos em [Almeida and Ludermir, 2007] e foram adaptados para trabalhar com os algoritmos genéticos celulares do AGCRN-CR.

A seleção de n indivíduos é realizada usando a estratégia de torneio, com uma taxa de pressão aleatória $p = 50\%$ e uma taxa de elitismo $e = 10\%$. Esta informação foi encontrada empiricamente após sucessivas execuções. O operador de seleção por torneio é usado tanto para seleção de sobreviventes como para seleção de pais para o cruzamento

Cada PPI está associada a uma arquitetura fixa pré-definida. Dessa forma todos os seus indivíduos possuem as mesmas dimensões e os operadores genéticos trabalham em um conjunto homogêneo de indivíduos de acordo com sua arquitetura. O cruzamento dessa população ocorre como descrito no algoritmo 1. Os filhos serão formados pelo cruzamento dos pais, que serão divididos ao meio para formar novos indivíduos. Esta idéia visa manter as correlações entre os pesos. Portanto, sejam a e b duas matrizes, as metades a_d , a_e , b_d e b_e são obtidas e irão definir a nova matriz filha, por exemplo, $w_{filho}=[a_d; b_e]$ ou $w_{filho} = [a_e; b_d]$

Uma vez que os indivíduos ainda não possuem uma aptidão, a seleção destes para o processo de mutação é feita aleatoriamente. A taxa de mutação empregada é de $m = 40\%$, quarenta por cento dos filhos passarão pelo processo de mutação e estes sofrerão mutação em 40% de sua composição. Este valor obtido no NNGA-DCOD foi encontrado após várias execuções e foi o valor que mais contribuiu para obtenção de bons resultados. Como forma de comparação igualitária o AGCRN-CR utiliza a mesma taxa. Esta mutação é feita através de matrizes esparsas com 40% de seus valores entre $fx = [-0.5, 0.5]$ e os demais valores definidos como zero. Estas matrizes esparsas serão adicionadas aos filhos gerando a mutação.

Algoritmo 1: Operador de cruzamento para indivíduos da PPI

Entrada: \mathbf{ppi}_n , w // pais, número de matrizes na rede
Saída: $\mathbf{vetFilhos}$ // filhos

```

1 inicio
2    $numFilhos \leftarrow 1$ 
3   enquanto  $numFilhos \leq (n/2)$  faça
4     para  $matriz \leftarrow 1:w$  faça
5        $metadeA \leftarrow fatia(\mathbf{ppi}_n(numFilhos).(matriz))$ 
6        $metadeB \leftarrow fatia(\mathbf{ppi}_n(numFilhos + 1).(matriz))$ 
7        $filho(matriz) \leftarrow [metadeA;metadeB]$ 
8      $\mathbf{vetFilhos} \leftarrow filho$ 
9      $numFilhos = numFilhos + 2$ 
10 fim

```

O fitness dos indivíduos da PPI é avaliado de acordo com o erro médio quadrático normalizado (normalized mean square error – NMSE) do conjunto de treinamento da rede.

Para indivíduos da PAF a aptidão I_{fit} é composta por quatro partes de informação, I_{acc} acurácia de classificação, I_{nmse} erro de treinamento, I_{comp} complexidade da rede e I_f peso da função de transferência utilizada.

$$I_{fit} = \alpha * I_{acc} + \beta * I_{nmse} + \gamma * I_{comp} + \delta * I_f \quad (1)$$

$$I_{acc} = 100 * \left(1 - \frac{correct}{total}\right) \quad (2)$$

$$I_{nmse} = \frac{100}{NP} * \sum_{j=1}^P \sum_{i=1}^N (d_i - o_i)^2 \quad (3)$$

$$I_{comp} = \frac{c}{c_{total}} \quad (4)$$

$$I_f = \sum_{h=1}^n f_{a_h} \quad (5)$$

Na equação 1, I_{acc} é a porcentagem de erro de classificação; I_{nmse} é o NMSE de treinamento gerado pela rede; I_{comp} é a medida da complexidade, considerando o número de nodos usados c e o número máximo de nodos possíveis c_{total} ; I_f calcula o peso das funções de transferências usadas. Para isso, cada função de transferência tem um peso associado empiricamente: Linear de 0.2, Tangente de 0.4 e Logaritmica de 0.7, priorizando funções de transferência simples, uma vez que o objetivo da metodologia é encontrar redes simples com alta performance; N e P o número total de saídas e o número total de padrões de treinamento respectivamente; d e o são as saídas desejadas e as saídas obtidas pela rede respectivamente. Como o AGCRN-CR busca redes com até 3 camadas escondidas e o valor de c_{total} é baseado no número de nodos de cada camada (entrada, saída e escondidos): $c_{total} = ent + esc + esc + esc + saida$. Neste trabalho o critério de classificação adotado foi o *winner-takes-all*, no qual o nodo de saída com maior valor vai determinar o padrão de classificação. O cálculo do I_{acc} ocorre através do critério *winner-takes-all*.

As constantes α , β , γ e δ possuem valores entre [0,1] e controlam a influência dos fatores sobre o processo global de aptidão. Por exemplo, para favorecer a precisão da classificação quanto ao erro de treinamento e complexidade, estas constantes são

definidas da seguinte forma $\alpha = 1$, $\beta = 0.90$, $\gamma = 0.90$ e $\delta = 0.20$. Assim, quando indivíduos aparentemente semelhantes forem encontrados, aquele que tiver o menor erro de treinamento, complexidade estrutural ou complexidade de função de transferência prevalecerá. Estes valores foram encontrados após sucessivas execuções. Como já citado anteriormente, o critério de aptidão leva em conta o NMSE da PPI em questão. Caso, durante a evolução da PAF, uma PPI acabe não possuindo tamanhos de vetores necessários à PAF evoluída, uma nova PPI será gerada (e posteriormente evoluída).

A busca por arquiteturas é feita para encontrar configurações com até três camadas escondidas e até 12 nodos por camada escondida. A seleção dos pais é feita pelo algoritmo 2, que começa definindo o número de camadas escondidas que os filhos terão, que será a média arredondada para cima ou para baixo dependendo de certa probabilidade. As dimensões de cada camada escondida e as funções de transferência serão escolhidas aleatoriamente, mas dentro dos limites da união das dimensões e funções de ativação dos pais. Estas etapas do algoritmo 2 se repetem até que o número de cruzamentos desejado seja atingido.

Algoritmo 2: Operador de cruzamento para indivíduos da PAF

Entrada: paf_n, n, k // pais, total de indivíduos, índice

Saída: $\mathit{vetFilhos}$ // filhos

```

1 inicio
2   enquanto  $k \leq (n/2)$  faça
3      $\mathit{totalCamadas} \leftarrow \mathit{paf}(k).\mathit{numCamEsc} + \mathit{paf}(k + 1).\mathit{numCamEsc}$ 
4     se  $\mathit{rand}(1) > \mathit{probs}$  faça
5       |  $\mathit{filho}.\mathit{numCamEsc} \leftarrow \mathit{ceil}(\mathit{totalCamadas}/2)$ 
6     senão
7       |  $\mathit{filho}.\mathit{numCamEsc} \leftarrow \mathit{floor}(\mathit{totalCamadas}/2)$ 
8      $\mathit{dimensoes} \leftarrow [\mathit{paf}(\mathit{numFilhos}).\mathit{dim}; \mathit{paf}(\mathit{numFilhos} + 1).\mathit{dim}]$ 
9      $\mathit{funcoes} \leftarrow [\mathit{paf}(\mathit{numFilhos}).\mathit{func}; \mathit{paf}(\mathit{numFilhos} + 1).\mathit{func}]$ 
10    para  $\mathit{elementos} \leftarrow 1:\mathit{dimensoes}_{\mathit{tamanho}}$  faça
11      |  $[\mathit{filho}.\mathit{dim}, \mathit{filho}.\mathit{func}] \leftarrow \mathit{sorteia}(\mathit{dimensoes}, \mathit{funcoes})$ 
12     $\mathit{vetFilhos} \leftarrow \mathit{filho}$ 
13     $\mathit{numFilhos} \leftarrow \mathit{numFilhos} + 2$ 
10 fim
```

O operador de cruzamento da PAF pode produzir indivíduos similares aos seus pais, ocasionado pela simplicidade do operador. Devido a isso, após o cruzamento é necessário a aplicação do operador de mutação para manter a diversidade da população. O Algoritmo 3 descreve a operação de mutação da PAF. Ele começa com a definição de filhos que sofrerão mutação. Em seguida é gerado um número aleatório no intervalo $[0,1]$. Este valor será utilizado como uma probabilidade que indicará se uma arquitetura irá sofrer um incremento ou decremento na quantidade de camadas ou no número de neurônios escondidos por camada. Na etapa de mutação, são avaliados todos os casos possíveis de quantidade de camadas (1, 2 ou 3). De acordo com uma determinada probabilidade o indivíduo pode ter sua quantidade de camadas aumentada ou sofrer uma redução de uma ou duas camadas. Caso o indivíduo tenha uma ou duas camadas ocultas, há maiores chances de este passar a ter 3 camadas (visando reduzir o número de nodos por camadas). A probabilidade de redução de camadas só é maior para indivíduos com 3

camadas ocultas (tendo maiores chances de ser 2 camadas). De forma geral, esta etapa prioriza gerar indivíduos com mais camadas e menos nodos por camada. Caso a probabilidade não atinja um valor esperado para adicionar ou remover camadas dentro das arquiteturas, ocorrerá uma mudança nas dimensões das camadas, ou seja, a arquitetura será mantida, mas a quantidade de nodos em cada camada será modificada através de valores gerados entre $arqval = [-2, 5]$ que serão adicionados as dimensões atuais da arquitetura (tendo no mínimo 1 e no máximo 12 nodos por camada). As PAFs são selecionadas de acordo com sua melhor aptidão que, como explicado anteriormente, leva em consideração a aptidão das PPIs (NMSE).

A pesquisa evolucionária por regras de aprendizagem acontece com a busca dos parâmetros dos seguintes algoritmos: Back-Propagation(BP), Levenberg-Marquardt (LM), quasi-Newton (QNA) e Gradiente Conjugado Escalonado (SCG). De acordo com o algoritmo de aprendizagem adotado, uma PRA terá parâmetros deste algoritmo para funcionar. Cada PRA tem uma PAF e sua aptidão é medida através da melhor aptidão dentre todas de sua PAF, ou seja, a PRA é selecionada de acordo com a configuração de parâmetros do algoritmo em questão que proporcione a melhor aptidão para a PAF. A seleção do indivíduo a partir da PRA também usa a estratégia de torneio. As taxas de mutação e elitismo são as mesmas apresentadas anteriormente. Como os indivíduos da PRA têm informações relacionadas a parâmetros do algoritmo de aprendizagem em questão, o seu cruzamento ocorre com a geração de novos valores dentro de um intervalo com base nos valores dos pais. De acordo com uma probabilidade os filhos realizam a mutação adicionando ou subtraindo valores as suas respectivas taxas. O valor da mutação nestas taxas é de 40% para mais ou para menos, dependendo também de uma probabilidade. O funcionamento geral do AGCRN-CR é apresentado no algoritmo 4 e a tabela 1 apresenta a lista de parâmetros utilizados.

O AGCRN-CR inicia sua busca gerando todos os indivíduos e calculando suas aptidões. Em seguida, os operadores genéticos são utilizados nas camadas em busca de novas soluções. Tais operadores tentam manter a diversidade genética utilizando a seleção por torneio, a mutação e o autômato celular, enquanto fazem a evolução das soluções. Como já citado, a manutenção da diversidade é um ponto considerado importante no uso de AGs, visto que tal diversidade evita que a busca caia em pontos de mínimos locais no espaço de pesquisa. A manutenção da diversidade com o uso do autômato celular é feita através da localidade, uma vez que os indivíduos só conseguem cruzar localmente, as chances de escapar dos pontos de mínimo local aumentam, diminuindo a possibilidade de convergência genética.

5. Resultados

Os experimentos foram realizados visando comparar os resultados do método AGCRN-CR em relação aos mesmos resultados com o NNGA-DCOD. Para isso foram utilizadas bases conhecidas do repositório UCI [Newman, et al. 1998]. As bases utilizadas foram Cancer com 9 atributos (atb), 699 exemplos (exp) e 2 classes (cla); Vidros com 9 atb, 214 exp e 6 cla; Cavalos com 58 atb, 364 exp e 3 cla; e Diabetes com 8 atb, 768 exp e 2 cla. A cada iteração os dados foram aleatoriamente divididos em metades. Uma das metades foi utilizada como entrada para os algoritmos com 70% de seus dados para treinamento e 30% para o conjunto de validação. A outra metade da base foi utilizada como conjunto de teste. Para determinar se os resultados obtidos possuem realmente significância estatística, foi utilizado um teste F com o auxílio do software BioStat 5.0.

Algoritmo 3: Operador de mutação para indivíduos da PAF

Entrada: *vetFilhos*, *n*, *m* // vetor com os filhos, número de filhos, taxa de mutação
Saída: *filhosMut* // Filhos mutados

```

1 inicio
2   quantidadeFilhos ← ((m/100) * n) faça
3   enquanto quantidadeFilhos > 0 faça
4     probabilidade ← rand(1)
5     filho ← sortear(vetFilhos)
6     se filho.numCamEsc = 1 faça
7       se probabilidade ≥ 0.6 faça
8         | filho ← adicionaCamadas(3)
9       senão se probabilidade ≥ 0.5 então
10        | filho ← adicionaCamadas(2)
11        senão
12          | filho ← filho + sorteia(arqval)
13        └─┘
14      senão se filho.numCamEsc = 2 então
15        se probabilidade ≥ 0.6 então
16          | filho ← adicionaCamadas(3)
17        senão se probabilidade ≥ 0.5 então
18          | filho ← reduzCamadaPara(1)
19          senão
20            | filho ← filho + sorteia(arqval)
21          └─┘
22        senão
23          se probabilidade ≥ 0.6 então
24            | filho ← reduzCamadasPara(2)
25          senão se probabilidade ≥ 0.5 então
26            | filho ← reduzCamadasPara(1)
27            senão
28              | filho ← filho + sorteia(arqval)
29              └─┘
29      vetFilhos ← vetFilhos – filho
30      filhosMut ← filho
31    quantidadeFilhos ← quantidadeFilhos – 1
32  filhosMut ← FilhosMut + vetFilhos
10 fim

```

O teste F é um teste de hipóteses que é aproximadamente distribuído com cerca de cinco a dez graus de liberdade e rejeita a hipótese nula de que os dois algoritmos têm a mesma taxa de erro com uma significância de 0,05 se $F > 4,74$. Esta metodologia foi utilizada devido ao fato do método usual (teste T de Student) gerar um aumento de erros do tipo 1, onde os resultados são erroneamente considerados diferentes com mais frequência do que o esperado, dado o nível de confiança utilizado.

O método NNGA-DCOD em [Almeida and Ludermir, 2007] teve melhores resultados que a busca manual e obteve RNAs mais compactas, rápidas e com bom poder de generalização. Neste estudo nós comparamos as soluções obtidas com base na informação de erro de dez conjuntos de testes e treinamentos obtidos pelos métodos AGCRN-CR e NNGA-DCOD na Tabela 2.

Algoritmo 4: Funcionamento geral do AGCRN-CR

Entrada: *parametros da Tabela 1*
Saída: *Um conjunto de redes neurais ótimas ou quase – ótimas// novos descendentes*

1 **inicio**
2 Gere aleatoriamente as populações de: Pesos iniciais (PPI), Arquiteturas e funções (PAF) e Regras de aprendizagem (PRA)
2 **para cada algoritmo de aprendizagem faça**
3 *Calcule a aptidão para todos os indivíduos*
4 **para cada geração \in BERA faça**
5 **para cada PAF \in PRA e geração \in BEAFA faça**
6 **para cada PPI \in PAF e geração \in BEP faça**
7 Crie um autômato celular At de acordo com o tamanho da população P ;
8 Insira em At a população de acordo com o seu fitness;
9 Crie um autômato auxiliar At_{aux} e faça-o igual a At
10 Inicie o cruzamento através do AGC;
11 Seja Q um número de filhos previamente determinado
12 **para numFilhos $\leftarrow 1: Q$ faça**

- Selecione aleatoriamente um indivíduo de At e selecione seus vizinhos por torneio;
- Comece o processo de cruzamento entre os vencedores do torneio para produzir descendentes
- Dependendo de uma probabilidade m aplique a mutação nos descendentes;
- Avalie os descendentes
- Se algum filho gerado for melhor que o pai, substitua o pai pelo filho na mesma posição no grid do autômato At_{aux}

13 Faça $At = At_{aux}$
14 Selecione entre todos os indivíduos, inclusive os novos, sobreviventes para próxima rodada
15 Repita os passos da BEP
16 Repita os passos da BEP
13 Selecionar redes quase-ótimas obtidas com cada algoritmo de aprendizagem
10 **fim**

A média das arquiteturas (arquit.) é baseada na quantidade de neurônios escondidos. O valor do teste F é dado na direita da tabela 2 para todos os casos estudados. De acordo com a tabela 2, ambos os métodos foram capazes de encontrar redes compactas com boa performance, mas o método AGCRN-CR teve resultados estatisticamente melhores de MSE que o método NNGA-DCOD em pelo menos metade dos testes para todas as bases de dados. Nas bases Cancer e Cavalos o AGCRN-CR obteve médias estatisticamente melhores em três dos quatro algoritmos avaliados. Nas bases Diabetes e Vidros o AGCRN-CR obteve melhores médias em dois dos quatro algoritmos avaliados. Segundo [Alba and Dorronsoro, 2008], os AGCs conseguem explorar o espaço de busca com maior eficácia, uma vez que a difusão lenta das soluções através da população fornece uma maior diversificação (*exploration*), enquanto a intensificação (*exploitation*) ocorre dentro da vizinhança por meio de operações genéticas.

6. Conclusões

Os algoritmos genéticos celulares possuem melhor equilíbrio entre a diversificação (*exploration*) e a intensificação (*exploitation*) quando comparados a um AG comum.

	Parâmetros para	Valores
AGs	<i>Modo de codificação</i>	Real
	<i>Taxa de Elitismo</i>	10%
	<i>Taxa de Mutação</i>	40%
	<i>Tipo de seleção</i>	Torneio
	<i>Número de indivíduos por população (PRA, PAF e PPI)</i>	4, 9, 9
	<i>Quantidade de gerações (BERA, BEAFA, BEP)</i>	18, 5, 3
	<i>Cálculo de aptidão</i>	Baseado no NMSE do conj. de treinamento
RNAs	<i>Tipo da Rede</i>	MLP feedforward
	<i>Algoritmos de aprendizagem empregados</i>	BP, LM, QNA, SCG
	<i>funções de transferência</i>	FL (linear), FLS (logaritmica Sigmoid) e FTH (tangente hiperbólica)
	<i>Número de camada escondidas</i>	até 3
	<i>Número de unidades escondidas</i>	até 12
	<i>Número de épocas de treinamento</i>	até 5
	<i>Intervalo para os pesos iniciais</i>	[-0.05, 0.05]
	<i>Função de transferência da última camada</i>	FL
Algoritmos de aprendizagem	<i>BP</i>	
	<i>Taxa de aprendizado</i>	[0.05, 0.25]
	<i>Momento</i>	[0.05, 0.25]
	<i>LM</i>	
	<i>Taxa de aprendizado</i>	[0.001, 0.02]
	<i>QNA</i>	
	<i>Tamanho do passo</i>	[1.0e-06, 100]
	<i>Limite do tamanho do passo</i>	[0.1, 0.6]
	<i>Fator de escala para determinar a performance</i>	[0.001, 0.003]
	<i>Fator de escala para determinar o tamanho do passo</i>	[0.001, 0.02]
<i>SCG</i>		
<i>Fator de controle para cálculo de aproximação da informação de segunda-ordem</i>	[0, 0.0001]	
	<i>Fator regulador da falta de definição da matriz hessiana</i>	[0, 1.0e-06]

Tabela 1 – Lista de parâmetros e valores

Problemas / Algoritmos	AGCRN-CR				NNGA-DCOD			Teste F
	Arquit.	Erros		Arquit.	Erros			
		Treino	Teste		Treino	Teste		
Cancer	BP	14	24.2726	24.3001	9	23.9684	23.9810	≤ 4.74
	LM	12.5	1.6778	2.0790	11.6	2.3036	2.5402	> 4.74
	SCG	11.9	4.4640	4.0842	12.5	5.2004	5.1257	> 4.74
	QNA	11.8	2.9263	2.6734	9.1	3.6066	3.3305	> 4.74
Diabetes	BP	7.1	23.9847	24.1965	12.2	24.3103	24.4491	> 4.74
	LM	16.6	13.6740	17.2658	12.3	14.1265	16.9845	≤ 4.74
	SCG	16.3	17.1709	20.1215	15.7	18.6435	21.0650	> 4.74
	QNA	12	18.7571	21.0253	16.5	17.6658	20.0718	≤ 4.74
Cavalos	BP	7.5	23.0633	22.6557	9.1	24.1395	23.9741	> 4.74
	LM	17.8	8.8731	15.8538	16.8	9.8776	15.1914	≤ 4.74
	SCG	12.6	15.1021	15.7953	17.9	16.1976	16.4628	> 4.74
	QNA	4.8	16.6637	16.1699	16.1	18.2964	17.2823	> 4.74
Vidros	BP	14	14.1346	13.5554	9.7	14.2789	13.8430	> 4.74
	LM	17.8	10.2865	11.0052	16.8	9.5976	11.7114	> 4.74
	SCG	17.9	12.1718	12.0891	18.8	12.3062	11.7663	≤ 4.74
	QNA	14.8	12.4402	12.6701	14.6	12.2023	11.2883	≤ 4.74

Tabela 2 – Resultados Experimentais

Devido a este equilíbrio, os AGCs conseguem escapar mais facilmente dos pontos de mínimo local no espaço de busca, conseguindo atingir, em média, melhores resultados

em relação a um AG comum, exatamente como o adotado pelo método NNGA-DCOD. Os resultados experimentais mostraram que, apesar do NNGA-DCOD ter obtido algumas redes um pouco mais compactas que o AGCRN-CR, na maioria dos casos o método celular obteve médias estatisticamente menores de MSE. Em trabalhos futuros há a pretensão de aplicar o método celular através de uma implementação paralela, visando acelerar a busca genética, uma vez que a pesquisa obteve resultados semelhantes em termos de tempo.

7. Agradecimentos

Os autores gostariam de agradecer a FACEPE, CNPq e CAPES pelo apoio financeiro.

8. Referências

- A. Abraham, (2004) “Meta learning evolutionary artificial neural networks”. In *Neurocomputing*, no. 56, pp. 1-38.
- D. J. Newman, S. Hettich, C.L. Blake, and C.J. Merz, (1998) “UCI repository of machine learning databases” [Online]. Available: <http://archive.ics.uci.edu/ml/>
- D. Simoncini, P. Collard, S. Verel, M. Clergue, (2007) “On the influence of selection operators on performances in cellular genetic algorithm.” In *CEC – 2007*, pp.4706-4713.
- E. Alba, B. Dorronsoro, (2008) “Cellular Genetic Algorithms”, In *Operations Research Computer Science Interfaces Series*, Vol. 42. ISBN – 978-0-387-77609-5
- E. Alba, and J. M. Troya, (2002) “Improving flexibility and efficiency by adding parallelism to genetic algorithms.” In *Statistics and Computing*, pages 91-114
- H. Rajabalipour, H. Haron, M. I. Jambak, (2009) “The Improved Genetic Algorithm for Assignment Problems”, In *ICSPS*, pp. 187 - 191.
- L. M. Almeida, (2007) “Uma metodologia de busca por redes neurais artificiais quase-ótimas.” Dissertação de mestrado – CIn - Centro de Informática - UFPE.
- L. M. Almeida and T. B. Ludermir (2007) “Automatically searching nearoptimal artificial neural networks.” In *ESANN*. pp. 549-554.
- N. Garcia-Pedrajas, C. Hervás-Martínez, and D. Ortiz-Boyer, (2005) “Cooperative coevolution of artificial neural network ensembles for pattern classification.” In *IEEE Trans. Evolut. Computation*, Vol. 9, no. 3, pp. 271-302.
- R. Linden, (2006), “Algoritmos genéticos – Uma importante ferramenta da inteligência computacional”, Rio de Janeiro. Brasport, 1ª edição
- S. Wright, (1943) “Isolation by distance.” In *Genetics*, 28, pp. 114 – 138
- S. Wolfram, (2002) “A New Kind of Science”, Wolfram Media, ISBN 1-57955-008-8
- X. Yao, (1999) “Evolving artificial neural networks.” In *Proceedings of the IEEE*, 87(9): pp. 1423-1447.
- Y. J. Cao, H. Q. Wu, (1998) “A Cellular Automata Based Genetic Algorithm and its Application in Machine Design Optimization.” In *ICC*, pages 1593 – 1598.