

Algoritmos Genéticos e *Particle Swarm Optimization* e suas aplicações problemas de Guerra Eletrônica.

CC (EN) Alexandre de Vasconcelos Siciliano – sicilian@ita.br, Tel +55-21-2104-5033
Diretoria de Sistemas de Armas da Marinha (DSAM) – Rua Primeiro de Março, 118
Centro – Rio de Janeiro, RJ - CEP 20010-000

Resumo — Uma estudo sobre Algoritmos Genéticos Simples (AGs) e *Particle Swarm Optimization* (PSO) – otimização por enxame de partículas – é apresentado. O Algoritmo Genético já vem sendo muito empregado nos últimos anos na solução de problemas de otimização na área de eletromagnetismo e de microondas. Contudo, apesar de grande eficácia do AGs, sua implementação, face ao modelo matemático adotado, envolve um alto custo computacional. Uma alternativa encontrada está no uso do PSO, que se aplica igualmente à otimização de problemas que recaiam em complexas funções não-lineares. A grande vantagem deste método, é a simplicidade de implementação e a facilidade de estruturação e compreensão.

Palavras-chaves — Algoritmos Genéticos Simples, e *Particle Swarm Optimization*.

I. INTRODUÇÃO

O Algoritmo Genético é um método amplamente utilizado nas aplicações de eletromagnetismo e microondas [1-5]. São algoritmos estocásticos de busca global, inspirados na teoria da evolução, proposta por Charles Darwin no século XIX em sua clássica obra “*On the Origin of the Species* (1859)”, impondo o princípio de sobrevivência do mais apto a fim de produzir soluções melhores a cada geração. Ou seja, a cada geração, uma nova população de indivíduos é criada a partir das informações genéticas dos melhores indivíduos da geração anterior, selecionados a partir de um critério específico. O método foi desenvolvido por Holland, J [6] e popularizado por um de seus alunos, David Goldberg.

A idéia do algoritmo é codificar soluções potenciais para um dado problema em uma estrutura simples (cromossomo) e aplicar a ela operadores de recombinação, de forma a preservar a informação crítica. Cada cromossomo consiste em um número de gene, sendo cada gene composto por bits. Os AG são capazes de pesquisar e encontrar mínimos locais ou globais, mas tem um custo computacional alto, tendo em vista, a necessidade da avaliação da totalidade da população a cada iteração do algoritmo. Uma contrapartida, para suplantar esta desvantagem é o método do PSO.

Introduzido por [7], o *Particle Swarm Optimization* (PSO) surgiu de experiências com algoritmos modelados a partir da observação do comportamento social de determinadas espécies de pássaros. As partículas consideradas pelo algoritmo se comportam como os pássaros à procura de alimento ou do local de seus ninhos, utilizando o aprendizado próprio e o aprendizado do bando (ou enxame). O PSO é composto de partículas representadas por vetores que definem a velocidade atual de cada partícula e de vetores

de localização, atualizados segundo sua velocidade atual, seu aprendizado pessoal e o aprendizado adquirido pelo bando. O algoritmo de PSO engloba conceituações simples e pode ser implementado em poucas linhas de programação, requerendo apenas operadores matemáticos simples.

Apesar de classificado como evolucionário, o PSO não apresenta a característica de sobrevivência do mais apto ou a utilização de operadores genéticos como o cruzamento e a mutação.

II. APRESENTAÇÃO DOS MÉTODOS CONSIDERADOS

A. Algoritmo Genético Simples

A figura 1 apresenta um fluxograma de execução de um AG, com o critério de parada que, no caso, é o valor da aptidão máxima.




Fig. 1 Fluxograma de um AG simples

Uma implementação típica de um AG começa pela geração de uma população inicial de cromossomos de forma aleatória. No AG básico o cromossomo consiste em uma *string*, geralmente binária, de comprimento L, como a mostrada na figura 2. Esta população é avaliada, de forma que aqueles indivíduos que representam uma melhor solução para o problema, recebem mais chances de se reproduzir e de gerar descendentes do que aqueles que oferecem soluções mais pobres. A aptidão (*fitness*) ou boa qualidade da solução é tipicamente definida em relação à população atual.




Fig. 2 String binária de comprimento L

No modelo proposto, a aptidão do indivíduo representa a oportunidade reprodutiva dele. Isto significa que quanto maior a aptidão de um indivíduo maior a chance de reproduzir e poder “passar a sua informação genética” adiante.

No processo evolutivo, na transição de uma geração para a outra, os indivíduos passam por um processo de

seleção natural, que escolhe quais são os indivíduos mais aptos a gerar os descendentes da geração seguinte.

Existem vários modos de se fazer a seleção [8]. Pode-se imaginar, por exemplo, a população disposta em um mapeamento sobre uma roleta, onde cada indivíduo é representado pelo espaço que proporcionalmente corresponde a sua aptidão. Para selecionar um indivíduo, um número aleatório é gerado para simular um giro da roleta até esse número. O indivíduo correspondente ao intervalo onde a roleta pára é selecionado. O processo é repetido até que se atinja o número desejado de indivíduos da nova população.

Um outro método de seleção muito empregado é o do torneio [8]. O processo se inicia com a ordenação da população por ordem decrescente de aptidão (*ranking*). Dentre aqueles indivíduos de maior aptidão será selecionado randomicamente um pequeno subconjunto de indivíduos que serão colocados para realizar o torneio. O indivíduo de maior aptidão ou aquele que superar um determinado limite previamente determinado será selecionado como sendo um dos genitores. Este processo ocorrerá tantas vezes quantas forem necessárias para se atingir a quantidade de genitores.

Em todos os métodos de seleção existe, ainda, a possibilidade de se optar pelo elitismo [8], que consiste na repetição incondicional do indivíduo melhor adaptado de uma geração na geração seguinte, para que não haja risco de se perder a melhor solução alcançada até aquele momento.

Os dois operadores genéticos mais empregados em um AG simples são o cruzamento (ou *crossover*) e a mutação [8].

A principal razão para se realizar o cruzamento é promover a geração de novos indivíduos a partir do material genético de seus antecessores, aproveitando o que há de melhor em cada um deles. Com isso, na medida em que as gerações avançam, cresce o número de descendentes com maior chance de sobrevivência, por estarem mais aptos.

Os algoritmos genéticos tradicionais geralmente usam o cruzamento simples ou de um ponto, onde dois indivíduos, o “pai” e a “mãe”, são cada um cortados em um ponto correspondente, conforme pode ser visto na figura 3 e seus segmentos, a partir do ponto de corte, são permutáveis.




Fig.3 Exemplo da operação de *Crossover* simples

A operação de cruzamento tem uma característica desfavorável em longo prazo, na busca do ótimo global por ser um operador que torna população mais homogênea. Após algumas gerações a população terá indivíduos semelhantes, que habitam uma região do espaço de busca, onde existe um ótimo que pode não ser necessariamente um ótimo global, indicando uma convergência prematura.

Para contornar o problema, é necessário incluir no AG um operador que torne a população mais heterogênea. Esse operador é a mutação.

O tipo de mutação mais empregado é a inversão, onde se escolhe um bit do indivíduo e inverte-se o seu valor. A figura 4 apresenta um exemplo de mutação por inversão.



Fig. 4 - operação de mutação por inversão em um indivíduo

Finalmente, nos AG podem ser estabelecidos dois critérios de parada, segundo os quais a evolução já teria completado seu objetivo: número de gerações ou tolerância. Na tolerância, a execução do algoritmo encerra-se após a constatação da existência de um indivíduo com as mesmas características do indivíduo-alvo, dentro de uma faixa de tolerância estabelecida.

B. Particle Swarm Optimization (PSO)

No modelo matemático adotado para o PSO, um “enxame de partículas” é gerado aleatoriamente em um determinado espaço de busca. Dentro deste espaço, cada partícula corresponde a uma possível solução, representada por sua posição no espaço de busca para um dado problema. As partículas têm associado um valor de velocidade e também realizam um deslocamento sob a ação de três vetores que se somam. Essas influências são a inércia, memória e comparação. O primeiro vetor impele a partícula em uma direção idêntica à que ela vinha seguindo. A memória atrai a partícula na direção da melhor posição até o momento, ocupado pela partícula dentro da sua vida. O último vetor atrai a partícula na direção do melhor ponto do espaço até o momento, descoberto pelo “enxame”. A figura 5 demonstra um exemplo de deslocamento de uma partícula, que se encontrava na posição x_{i-1} , para a posição x_i fazendo uso dos vetores mencionados.

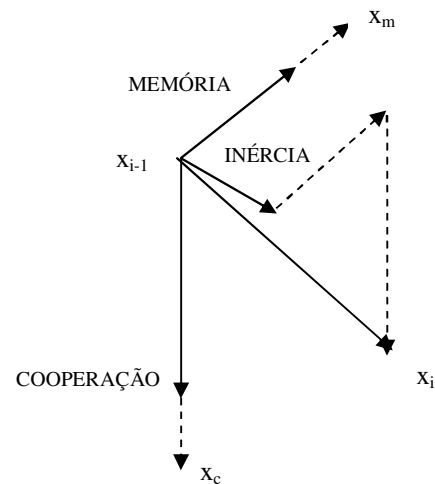


Fig. 5 – Movimento de uma partícula [9]

Na implementação do algoritmo, o primeiro passo é gerar as N partículas que formarão o *swarm* ou o “enxame” com suas respectivas posições. Pode-se também neste momento, arbitrar velocidades iniciais para cada partícula. O algoritmo manter-se-á ativo, atualizando os vetores de velocidade e posição ciclicamente até que seja atingido qualquer critério de parada (número máximo de iterações atingido, partícula com aptidão desejada, etc.).

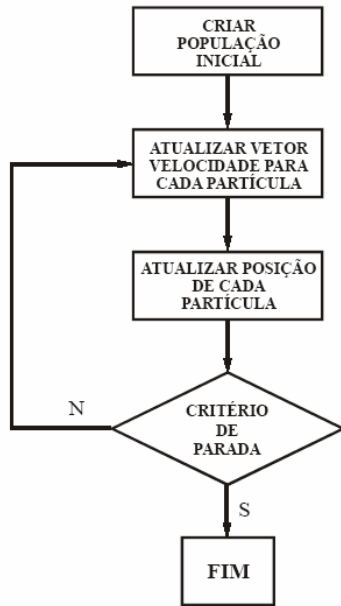


Fig. 5 – Fluxograma do PSO [10]

O vetor velocidade de cada partícula deve ser atualizado por (1).

$$v_{k+1}^i = w.v_k^i + c1.r1.(p^i - x_k^i) + c2.r2.(p_k^s - x_k^i) \quad (1)$$

Onde v_k^i é a velocidade atual da partícula, p^i é a melhor posição encontrada pela partícula i , p_k^s é a melhor posição dentre todas as partículas na iteração k , w é um parâmetro que representa a inércia da partícula e controla a sua capacidade de exploração do espaço de soluções. Um valor alto determina uma busca global enquanto um valor baixo determina uma busca local. Usualmente estes valores oscilam entre 0,4 e 1,4, $c1$ e $c2$ são os chamados parâmetros de confiança e definem o quanto uma partícula confia em si ($c1$) ou no bando ($c2$). Usualmente ambos assumem o valor igual a dois, e $r1$ e $r2$ são números aleatórios compreendidos entre zero e um.

Para o cálculo da posição futura de cada partícula no algoritmo é utilizada (2).

$$x_{K+1}^i = x_k^i + v_{k+1}^i \quad (2)$$

Onde:

x_{K+1}^i é a posição de cada partícula i na iteração $k+1$; e

v_{k+1}^i é o vetor velocidade da partícula

III – USO DO AG E DO PSO NA OTIMIZAÇÃO DE FUNÇÕES

Visando a demonstrar a potencialidade e a permitir uma avaliação de ambos os métodos apresentados, os dois algoritmos foram empregados na otimização de funções de teste. O objetivo é a minimização da Eq. (3) e a maximização da Eq. (4).

$$f(x, y) = 100(y - x^2)^2 + (x - 1)^2 \quad (3)$$

$$f(x, y) = \frac{1}{2} [\cos(16\pi x) + \cos(16\pi y)] e^{-\frac{7}{2} \left[\left(x - \frac{1}{2}\right)^2 + \left(y - \frac{1}{2}\right)^2 \right]} \quad (4)$$

O ponto de mínimo de (3) é (1,1) e o ponto de máximo de (4) é (1/2, 1/2). As figuras 6 e 7 apresentam as funções a serem analisadas.




Fig.6 aspecto da função a ser minimizada




Fig.7 aspecto da função a ser maximizada

O software utilizado para realizar os algoritmos do AG e do PSO foi o MATLAB v7.2. Para a minimização de (3), o algoritmo genético foi implementado com seleção por roleta, taxa de *crossover* de 80%, taxa de mutação de 1% e população inicial de 20 indivíduos. Para a minimização da mesma função, o PSO foi implementado com 20 indivíduos, $c1$ e $c2$ igual a 2 e com w variando entre 0,4 e 0,9. A tabela I resume os resultados obtidos para o AG e o PSO.

TABELA I – VALORES OBTIDOS PARA O PONTO DE MÍNIMO DE (3).

Qtd de gerações	GA		PSO	
	x	y	x	y
50	1,0691	1,01567	1,00690	1,05493
100	1,00690	1,01567	0,99999	0,99999

Para a maximização de (4), o AG foi implementado com seleção por roleta, taxa de *crossover* de 80%, taxa de mutação de 1% e com 20 indivíduos. Como a função é mais complexa, a quantidade de gerações (200) necessárias para se obter um resultado com erro da ordem de 10^{-3} foi muito maior.

Para a mesma função o PSO, foi implementado com 20 indivíduos, parâmetros de confiança $c1$ e $c2$ iguais a 2 e inércia da partícula w variando entre 0,4 e 0,9. A tabela II apresenta os resultados e conforme se verifica, com uma quantidade menor de iterações, o PSO convergiu para o valor esperado.

TABELA II – VALORES OBTIDOS PARA O PONTO DE MÁXIMO DE (4).

Qtd de iterações	AG		PSO	
	x	y	x	y
50	0,49906	0,37964	0,3729	0,4999
100	0,50577	0,50035	0,5000	0,5000
150	0,50130	0,49903	0,5000	0,5000
200	0,50063	0,50053	0,5000	0,5000

Abaixo são apresentadas as figuras 8 e 9 onde se encontram a evolução das partículas para as funções estudadas. Verifica-se que em ambas, na fase inicial do PSO, as partículas estão dispostas aleatoriamente dentro do espaço de busca. A medida em que as iterações aumentam, percebe-se uma tendência de deslocamento das partículas para a posição ótima (que pode ser um ponto de mínimo ou de máximo, conforme o caso em estudo).

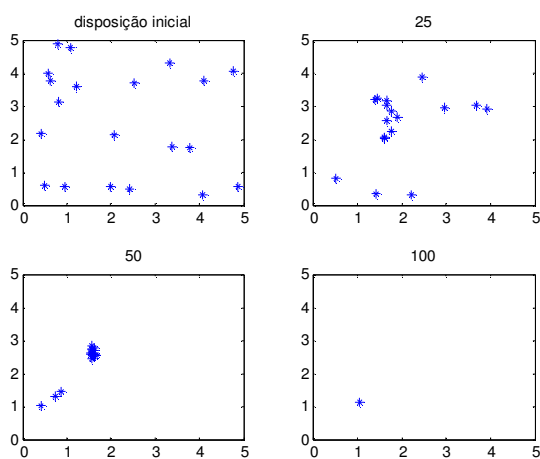


Fig 8 – Evolução das partículas para a Eq. (3), com 100 iterações

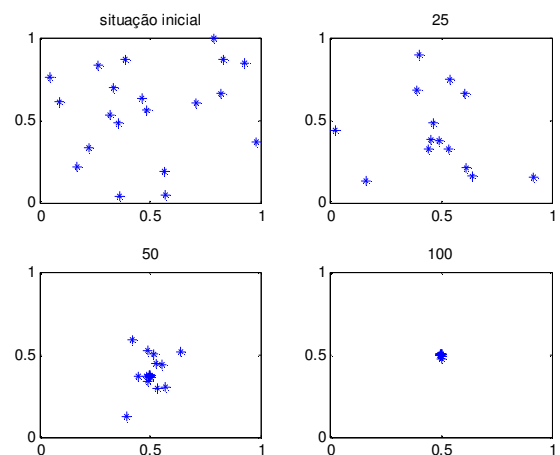


Fig 9 – Evolução das partículas para a Eq. (4), com 100 iterações

IV APLICAÇÃO DOS ALGORITMOS EM GUERRA ELETRÔNICA

Para demonstrar o emprego destes algoritmos, na área de Guerra Eletrônica, abaixo são apresentadas três aplicações em que se necessita realizar a otimização de funções. Os exemplos citados utilizam Algoritmos Genéticos. O PSO, por ser pesquisa recente, ainda não possui muitos trabalhos nesta área. Mas certamente os resultados demonstrados com o uso do PSO incentivam o seu uso nas pesquisas associadas ao tema de Guerra Eletrônica.

A) Aplicação em Projeto de Antenas Filamentares [1,11]

Existe uma classe de radiadores eletromagnéticos denominada antenas filamentosas. Elas são assim chamadas por serem constituídas por fios cujos diâmetros são muito menores que seu comprimento. Nesta classe estão inseridas as antenas monopolo, as antenas dipolo e as antenas do tipo Yagi-Uda. Esta última é composta por um conjunto de elementos paralelos, sendo um deles o elemento refletor, geralmente seguido pela antena propriamente dita (do tipo dipolo) e por uma seqüência de diretores, em quantidade variada de acordo com as necessidades do projeto. Antenas deste tipo são reconhecidamente difíceis de serem projetadas e otimizadas. A diretividade, o ganho e a sensibilidade dependem da relação existente entre os diversos elementos que a compõe. No projeto, devem ser considerados os comprimentos de cada elemento (comprimento este, expresso em função do comprimento de onda da frequência em que a antena irá trabalhar), a distância entre cada um deles e a quantidade de elementos diretores que a antena deverá ter para atuar como desejado. Percebe-se a natureza complexa deste tipo de projeto.

O AG é então empregado em associação com softwares de simulação de antenas. A população é criada, e cada indivíduo será avaliado pelo simulador, que devolverá a resposta ao AG. O algoritmo genético fará então evoluir a população em busca do resultado ótimo.

Os resultados obtidos nas pesquisas com as antenas filamentosas mencionadas vêm estimulando o desenvolvimento de antenas que fazem uso de combinações delas, como se pode ver nas figuras abaixo:




Fig. 10 – Antena monopolo carregada com antena dipolo dobrada

B Aplicação em Materiais Absorvedores de Radiação Eletromagnética (MARE) [11]

Existem pesquisas utilizando o algoritmo genético para sintetizar material absorvedor de radiação eletromagnética (MARE) de pouco peso, com multicamadas e de banda larga. A idéia principal deste tipo de projeto é empregar o material desenvolvido em aeronaves, onde o peso e a espessura do MARE são críticos.

O emprego do AG neste tipo de projeto, leva em consideração um conjunto de vários tipos diferentes de materiais absorvedores disponíveis e também a refletividade da onda eletromagnética em um grande número de ângulos de incidência. A elaboração do algoritmo ocorre da seguinte forma. Inicialmente é gerado um banco de dados, relacionando todos os tipos de MARE disponíveis e suas características principais. A codificação do cromossomo é binária e cada camada de MARE empregada é representada por bits do cromossomo. Esses bits codificam a espessura da camada e identificam o material a ser empregado pelo apontamento da entrada no banco de dados. A função da aptidão escolhida minimiza a refletividade para vários ângulos de incidência e de várias frequências e inclui penalidades para a espessura total.

Existem trabalhos relatando projetos bem sucedidos de MARE, com espessuras minimizadas e coeficientes de reflexão também minimizados nas faixas de frequências de 0.5-8 GHz, e de 2-8 GHz.

C Aplicação em Otimização de Cobertura Radar [12]

A utilização de radares terrestres permite a vigilância de uma ampla área territorial, sendo de grande importância para a defesa de um país. A determinação da melhor distribuição de radares em certa região é uma tarefa difícil em decorrência, principalmente, da sensibilidade dos sinais dos radares às características climáticas e ao relevo da região. Desta forma, é importante a otimização do posicionamento dos radares, com o intuito de aumentar a eficiência da cobertura total do sinal gerado, determinando a melhor distribuição de um conjunto de radares em um conjunto de possíveis posições de instalação, visando a maximizar a área de cobertura do sinal gerado.

No trabalho pesquisado, o AG foi utilizado juntamente com o GPC (*Generic Polygon Clipper*), uma biblioteca que permite efetuar os cálculos das uniões entre a cobertura de sinais radares.

O indivíduo gerado é definido como uma possível distribuição ou posicionamento de um número de radares a partir de algumas posições de instalação. O cromossomo do indivíduo é um vetor composto por tantos componentes

quanto forem os radares, onde cada componente contém o índice de uma posição, dentre a totalidade de posições, onde está instalado um dos radares. Os resultados obtidos apresentam soluções mais precisas que as obtidas em trabalhos anteriores, que utilizam aproximações circulares para as coberturas dos sinais dos radares.

V CONCLUSÃO

Dois algoritmos para otimização de funções não-lineares foram apresentados neste artigo. A fim de testar a efetividade dos mesmos, duas funções de teste foram propostas. Uma simples, sem mínimos locais e outra com diversos mínimos e máximos locais. Analisando os dados das tabelas I e II, verifica-se que o PSO teve desempenho melhor do que o AG, convergindo com menos iterações.

O AG é um algoritmo amplamente difundido e utilizado, já possuindo diversas aplicações em Guerra Eletrônica e microondas, conforme exposto na seção IV. É um método eficaz, mas que, devido à sua formulação matemática, possui um custo computacional alto.

Durante a realização deste trabalho, não foram encontrados artigos apresentando aplicações do PSO em Guerra Eletrônica. Mas, face ao exposto na seção III, percebe-se que sua aplicação nesta área pode culminar em resultados ainda melhores do que aqueles obtidos com o AG.

VI REFERÊNCIAS

- [1] Altshuler, E. E. e D. S. Linden. Wire-Antenna Designs Using Genetic Algorithms. IEEE Antennas and Propagation Magazine. 39: 33-43 p. 1997.
- [2] Johnson, J. M. e Y. Rahmat-Samii. Genetic Algorithms in Engineering Electromagnetics. IEEE Antennas and Propagation Magazine. 39: 7-21 p. 1997.
- [3] Mognon, V. R. Algoritmos Genéticos Aplicados na Otimização de Antenas. (Mestrado). Engenharia Elétrica, Universidade Federal do Paraná, Curitiba, 2004. 85 p.
- [4] Ramos, R. M., R. Saldanha, et al. Otimização Multiobjetivo Aplicada ao Projeto de Antenas Filamentares. Ciência & Engenharia (Science & Engineering Journal), v.Edição Especial, p.67-70. 2003.
- [5] Soares, G. L. Algoritmos Genéticos: Estudo, Novas Técnicas e Aplicações. (Mestrado). Engenharia Elétrica, Escola de Engenharia Elétrica da Universidade Federal de Minas Gerais, Belo Horizonte, 1997. 137 p.
- [6] Holland, J. H., Adaptation in Natural and Artificial Systems, Ann Arbor, The University of Michigan Press, 1975
- [7] Kennedy, J. e R. Eberhart. Particle Swarm Optimization. IEEE International Conference on Neural Network. Perth, Australia, 1995. 1942-1948 p.
- [8] Whitley, D., A Genetic Algorithm Tutorial, Statistics and Computing, v. 4, pp. 65-85, 1994.
- [9] Borges, G. S. Desenvolvimento de Ambientes Computacionais para Análise de Dispositivos e Sistemas para Redes de Comunicações Ópticas e Móveis. Universidade Federal do Pará. Pará, p.54. 2006
- [10] Menezes, N. G. Síntese Topológica Evolucionária e Otimização Numérica de Parâmetros em Estrutura CMOS. (Mestrado). Engenharia Elétrica, COPPE/UF RJ, Rio de Janeiro, 2007. 59 p.
- [11] Johnson M. J., e Rahmat-Samii Y., *Genetic Algorithms in Engineering Electromagnetics*. IEEE Antennas and Propagation Magazine, Vol. 39, No. 4, August 1997.
- [12] Medeiros, F. L. L., Dos Santos, C. R. L., De Marchi M. M. e Pinto, M. J., *Algoritmo Genético Aplicado à Otimização da Cobertura do Sinal gerado por Radares Terrestres*. XXV Congresso da Sociedade Brasileira da Computação – Unisinos, São Leopoldo, RS – 2005.