

PROPOSTA PARA MÉTODO DE INSEMINAÇÃO ARTIFICIAL COM SOLUÇÕES ELITE EM ALGORITMOS GENÉTICOS

Raul de Souza Brandão

IFES – Instituto Federal do Espírito Santo
Cachoeiro de Itapemirim – ES
prof-raul@hotmail.com

Jacqueline Magalhães Rangel Cortes

UENF – Universidade Estadual do Norte Fluminense
Campos dos Goytacazes – RJ
jmrc@uenf.br

Pábola Damian Ferreira Venancio Brandão

USC – Universidad San Carlos
Asunción – PY
pabolavenancio@bol.com.br

Resumo

O presente trabalho foi desenvolvido no âmbito da disciplina de Inteligência Artificial do Doutorado em Informática da Universidade San Carlos. Apresenta uma nova proposta de algoritmo. Parte do princípio de fornecer um instrumento dinâmico entre diversas técnicas amplamente conhecidas na literatura, de modo que seja um recurso facilitador nesse contexto. São apresentadas as principais características do algoritmo, bem como são demonstrados os testes para validar a eficiência do mesmo.

Palavras-chave: Algoritmo Genético; Inseminação Artificial, Soluções Elite.

1. Introdução

Os algoritmos evolutivos (AEs) são aqueles que usam modelos computacionais inspirados nos processos naturais de evolução como ferramenta para resolver problemas (LINDEN, 2008). A programação evolutiva (PE) proposta por Fogel (1962) tem como objetivo utilizar os conceitos de evolução no desenvolvimento da Inteligência Artificial (IA).

A PE e outras técnicas como os algoritmos genéticos (AG's) são partes da IA que foram e continuam sendo fundamentais para desenvolver de diversas pesquisas que envolvem problemas de grande complexidade. Como exemplo, pode ser citado os problemas NP-completos, que segundo Varela (2007) caem dentro do âmbito de resolução dos AG's.

Os AG's são métodos heurísticos de busca estocástica, baseados no processo de evolução biológica que favorece o alcance do ótimo global ou aproximação satisfatória. Estes algoritmos se baseiam na teoria da evolução por seleção natural de Darwin e nos experimentos do cruzamento genético de ervilhas proposto por Mendel. Essas teorias são utilizadas como técnicas para busca de soluções, que tem por inspiração a seleção e genética natural (GOLDBERG, 1989).

2. Algoritmo Genético com Inseminação de Soluções Elite

A proposta desse estudo visa apresentar um Algoritmo Genético mais eficiente por meio da introdução de conceitos baseados na inseminação artificial através de soluções elite. Logo propõem se utilizar um novo parâmetro no algoritmo a ser definido e controlado pelo agente decisor que utilizar a técnica proposta. Trata-se da probabilidade de inseminação. Ainda nessa técnica proposta, existe a possibilidade de controlar a aleatoriedade do algoritmo através dos parâmetros mínimos e máximos para mutação e cruzamento.

A proposta de desenvolver uma melhoria na eficiência dos algoritmos genéticos dá-se pela comprovação de diversas pesquisas, onde os mesmos são considerados como bons para abordagens satisfatórias que possuam espaço de busca potencialmente imenso e onde combinações ótimas poderiam demorar até mesmo o tempo de uma vida para ser encontradas (MANGANO, 1995).

Os AG's são representados computacionalmente através da inspiração dos conceitos genéticos citados acima, essa representação se dá por meio de uma codificação de parâmetros e indivíduos no algoritmo. O entendimento dos AG's pode ser facilmente compreendido pelos seguintes conceitos.

Genes: Blocos funcionais do DNA do cromossomo;

Cromossomo: Conjunto de genes que forma cada indivíduo que representam as soluções.

População: Conjunto de indivíduos (cromossomos) que formam as soluções;

Aptidão: Medida de adaptabilidade e desempenho de um indivíduo na população;

Seleção: Mecanismo responsável por selecionar os indivíduos mais aptos para o cruzamento. Sendo os principais métodos de seleção existentes e amplamente conhecidos na literatura são: torneio, elitismo e diversidade. Estes métodos são utilizados combinados com:

a) Cruzamento: Também conhecido como *crossover*, é a mistura de genes de dois indivíduos para gerar um descendente (filho). Existem vários tipos de cruzamentos, com destaque, os mais conhecidos e utilizados são: ponto de corte, uniforme e máscara;

b) Mutação: É uma probabilidade de um gene do indivíduo sofrer uma alteração aleatória ou mesmo direcionada após a geração de um descendente, isto é, após ser realizado um cruzamento entre dois ou mais indivíduos. Existem na literatura várias abordagens para

a utilização de mutações em algoritmos genéticos, em destaque, podemos citar duas como as mais conhecidas.

- i) Inversão: Modifica o valor gene onde ocorre a mutação;
- ii) Troca de posição: Altera posição de um ou mais genes, sem mudar seu valor, isto é, modifica a localização do mesmo, alterando apenas o valor do cromossomo e não do gene.

2.1. Representação dos Genes e Cromossomo

O cromossomo é a representação básica do indivíduo. A Figura 1 ilustra dois tipos de codificação para indivíduos de população utilizados em AG's.

A primeira representação tem-se uma estrutura binária, onde os cromossomos são codificados em um conjunto de símbolos chamados genes que são representados por um valor 0 ou 1, estes podem representar uma característica ausente ou presente no indivíduo. Já na segunda codificação ilustrada na Figura 1, um conjunto de caracteres representa os genes, esse tipo de código é mais completo e utilizado em problemas mais complexos, onde o nível de detalhamento necessário é maior.




Figura 1: Representações básicas de cromossomos.

2.2. Representação da População

A população em algoritmos genéticos é o conjunto de soluções disponíveis e encontradas pela técnica. A melhoria eficaz a cada geração dessa população é o princípio básico do conceito evolutivo do algoritmo. A população tende a evoluir a cada nova geração criada. Para gerar uma nova geração é necessário aplicar os conceitos de cruzamento e mutação. A Figura 2 ilustra alguns conceitos de indivíduos pertencentes a uma determinada população.




Figura 2: Indivíduos que representam a população.

No início da Figura 2 temos o indivíduo Pai, que é a representação de um indivíduo com boa aptidão que passou por um método de seleção e foi escolhido para gerar um descendente. Descendente esse que será formado por esse Pai e por outro indivíduo que chamamos de Mãe (também conhecido na literatura como Pai 2).

Temos nessa figura a representação da solução elite, essa solução é um indivíduo da população com maior aptidão encontrada até o momento ou mesmo na população em questão, trata-se do indivíduo mais apto.

Aleatório é um indivíduo gerado aleatoriamente, basicamente está presente em 100% da população inicial e em alguns casos são encontrados no decorrer da população.

Indivíduo inseminado, esse será abordado mais a frente desse documento, pois se trata do cruzamento de um indivíduo qualquer da população com o indivíduo elite.

2.3. Representação da Seleção

A seleção em algoritmos genéticos é técnica aplicada para encontrar os indivíduos mais aptos para gerar a nova população (descendentes). Essa técnica se baseia basicamente em selecionar dois os mais indivíduos na população atual, verificar sua capacidade como solução (aptidão) e comparar entre si e selecionar o mais apto.

Essa seleção é realizada para selecionar cada um dos pais que formará o novo indivíduo (filho ou descendente). Algumas técnicas podem ser utilizadas na aplicação da seleção, nesse trabalho apresentaremos a técnica de torneio de 3. Esses métodos constituem-se de selecionar 2 indivíduos aleatoriamente na população e comparar os mesmos.

Seleção do Pai: São sorteados três indivíduos na população atual, são comparadas suas aptidões e selecionado o mais apto.

Seleção da Mãe: São sorteados novamente mais três indivíduos na população atual e selecionado o indivíduos considerado mais apto.

Pode ser observado na Figura 3 que o método empregado é o torneio de 3. Basicamente a figura ilustra o sorteio de três indivíduos na população atual, e para entendimento da seleção que ocorrerá, é demonstrada a aptidão desses indivíduos em relação a sua altura, isto é, a ilustração apresenta indivíduos com tamanhos diferenciados, sendo então que o pai a ser selecionado será o indivíduo marcado como 2 e a mãe o indivíduo marcado como 1.

Nota-se que a aptidão dos mesmos em relação à altura deixa claro essa condição, pois esses são os indivíduos mais altos em cada um dos sorteios realizados. Assim por uma avaliação de altura esses indivíduos sorteados aleatoriamente na população são considerados mais aptos para gerar descendentes.




Figura 3: Torneio de 3: Comparação entre indivíduos mais altos.

2.4. Representação do Cruzamento

O cruzamento em algoritmos genéticos é técnica aplicada para gerar os novos indivíduos da nova população, técnica para utilizada para geração de descendentes. Após aplicar uma técnica de seleção dos pais, é realizado o cruzamento entre esses indivíduos. Os pais são aqueles indivíduos que possuem a melhor avaliação, ou seja, os indivíduos sorteados considerados mais aptos para formar novas soluções.

Para entendimento básico será apresentada uma das técnicas mais utilizadas nos AG's, trata-se do cruzamento de um ponto. Essa técnica consiste em aproveitar parte do primeiro indivíduo selecionado (pai) com parte do segundo indivíduo (mãe), sendo que essa parte é previamente definida, isto é, um definido um ponto de corte no cromossomo, onde são cruzados os genes dos indivíduos selecionados.

A Figura 4 ilustra o cruzamento de um ponto, pode ser observado nessa figura que as ilustrações indicam que a primeira metade do cromossomo que forma o indivíduo descendente será originada do pai e a segunda metade da mãe. Essa técnica reflete apenas uma possível combinação entre os indivíduos para técnica de cruzamento de um ponto.




Figura 4: Cruzamento de um ponto.

2.5. Representação da Mutação

A mutação em algoritmos genéticos é técnica aplicada após a formação do novo indivíduo, ou seja, caso haja um cruzamento entre dois indivíduos da população, poderá haver uma mutação genética, isto é, o indivíduo gerado não será necessariamente cópia de parte do pai e da mãe, pois sofrerá uma espécie de alteração em seu cromossomo após o cruzamento.

A Figura 5 ilustra um exemplo de um indivíduo que sofreu uma mutação, nela podemos observar que uma parte de seu cromossomo é alterada, isto é, um gene é modificado, assim o indivíduo deixou de ter seu cromossomo formado por uma cópia de parte dos cromossomos de seus pais. Porém observa-se ainda que essa alteração é e deve ser sutil, ou seja, uma pequena parte que sofre a alteração desejada, neste exemplo é alterado o valor do gene, técnica conhecida como mutação que modifica o valor do gene.

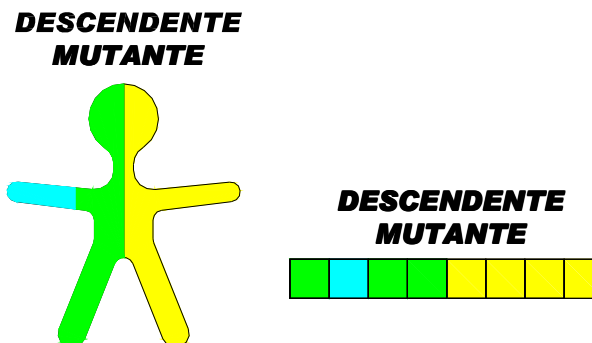


Figura 5: Descendentes que sofreu mutação.

2.6. Parâmetros de um Algoritmo Genético

Os AG's são formados por diversos parâmetros a serem ajustados pelo agente decisor do sistema. Nele deverão ser colocados os dados para a evolução da população seja a melhor possível. Basicamente os AG's possuem os seguintes parâmetros: Tamanho da

população; Número de Gerações; Probabilidade de Cruzamento; Probabilidade de Mutação, Tipo de Seleção; Tipo de Cruzamento; Tipo de Mutação.

Nessa proposta de estudo acrescentamos os seguintes parâmetros para serem utilizados em AG's: Probabilidade de Inseminação, sendo que a mesma possui um intervalo mínimo e máximo.

Ainda foram acrescentados as Probabilidades de Cruzamento e Mutação intervalos mínimos e máximos. Sendo essas explicadas mais a frente desse documento, onde a representação do algoritmo deixará mais evidente esses conceitos novos.

3. Representação do Algoritmo Proposto

O AG proposto pode ser entendido pela representação gráfica apresentada na Figura 6. A figura ilustra os passos do algoritmo. É apresentado um problema, o agente decisor deve inicializar os parâmetros, assim uma população inicial será gerada. A geração inicial é formada por indivíduos gerados aleatoriamente. Os cromossomos são gerados para codificar o problema.

Na avaliação os cromossomos são medidos, é verificada a aptidão dos indivíduos e se os critérios para encerrar o algoritmo foram alcançados. Se sim, encerra a execução e apresenta o resultado com a solução encontrada, se não, são sorteados indivíduos da população, é realizada uma seleção dos indivíduos mais aptos, que formaram os pais e são descartados os indivíduos menos aptos.

Caso haja probabilidade para cruzamento, serão gerados os descendentes com os pais selecionados, se não, verifica-se a possibilidade de realizar uma inseminação, se sim, haverá um cruzamento com um dos pais selecionados com a solução elite do problema (melhor solução encontrada até o momento), se não, gera descendentes aleatórios.

Caso haja probabilidade de mutação, os descendentes gerados são alterados e passam a fazer parte da nova população, nos casos que não, os mesmos se mantêm inalterados e passam a fazer parte da nova geração. O ciclo do algoritmo reinicia nesse ponto, onde novamente são avaliados e verificados se a solução satisfaz o problema.

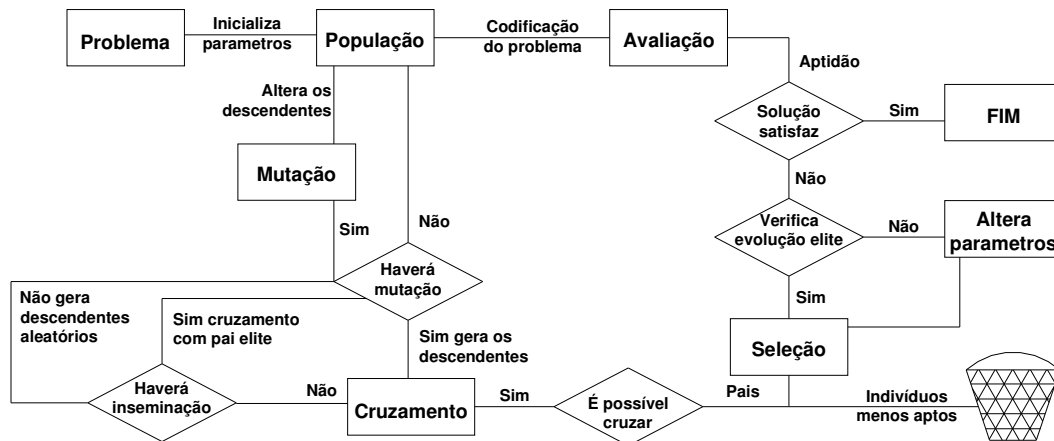


Figura 6: Representação gráfica do algoritmo proposto.

Alguns parâmetros do algoritmo são alterados dinamicamente, são eles, probabilidade de mutação, cruzamento e inseminação. É testada no algoritmo a evolução das soluções elite, caso não haver evolução em um determinado número de gerações, esses parâmetros são alterados para melhorar o desempenho do algoritmo. Os passos do algoritmo são representados na Figura 7. A mesma retrata o pseudocódigo do algoritmo proposto nesse documento.

```

1 Algoritmo Genético com Inseminação Artificial
2 Início
3   G <= 0
4   ConfiguraParametros
5   Inicializa (P,G)
6   Avalia (P,G)
7   ArmazenaSoluçãoElite (P,G)
8   Enquanto (não condição de parada) faça
9     G <= G + 1
10    Seleção (P,G) a partir de (P,G-1)
11    Testa ProbabilidadeCruzamento
12      Se sim, GeraFilhosPorCruzamento (P,G)
13      Se não, testa Probabilidade Inseminação
14        Se sim, GeraFilhosPorInseminação (P,G)
15        Se não, GeraFilhosAleatórios (P,G)
16    Testa ProbabilidadeMutaçao
17      Se sim, AlteraFilhos (P,G)
18    Avalia(P,G)
19    ArmazenaSoluçãoElite (P,G)
20    Testa EvoluçãoElite
21      Se não, AlteraParametros
22  FimEnquanto
23  ApresentaResultados
24 FimAlgoritmo

```

Figura 7: Representação do código do algoritmo proposto.

4. Aplicação do Algoritmo e Testes

Para o estudo foram escolhidos dois problemas a serem aplicados. Trata-se de dois problemas de maximização sendo um com um objetivo e um problema com dois objetivos a serem maximizados utilizando média ponderada nas funções. Os testes foram realizados com um algoritmo genético comum e o outro com a proposta desse documento.

O algoritmo genético proposto inclui algumas funções ao algoritmo genético comum, as linhas 12 até 14 da Figura 7 são a representação dessas novas funções.

Na Figura 8 é ilustrada a tela do algoritmo proposto nesse documento. Na tela poderá ser observado as funções utilizadas no teste, os parâmetros aplicados no algoritmo, os métodos de seleção, cruzamento e mutação aplicados, o resultado, o tempo de execução, a evolução das soluções elites nas gerações.

A ilustração da Figura 8 visa apresentar a implementação do algoritmo proposto, essa implementação foi realizada em linguagem de programação Object Pascal, utilizando a IDE Delphi 7 do fabricante Borland.

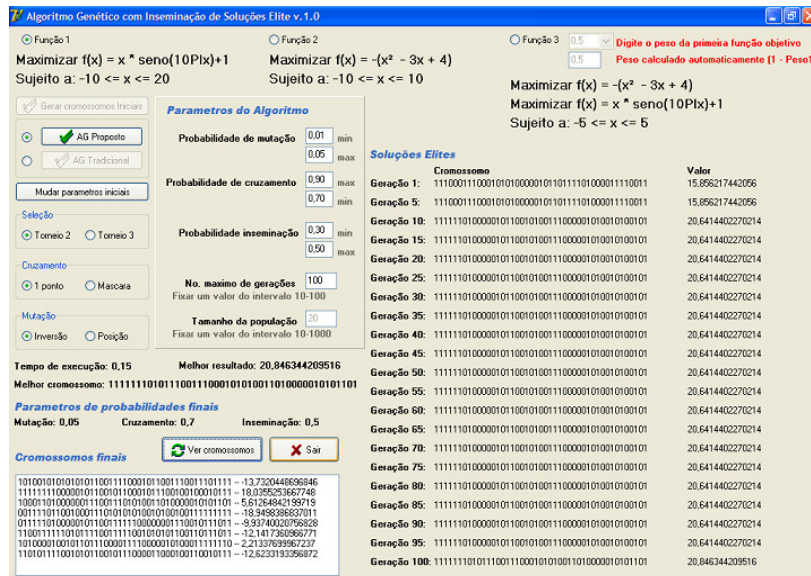


Figura 8: Tela do Algoritmo Proposto.

4.1. Estudo de Caso 1

Para o primeiro estudo de caso, foi aplicada uma simples função de maximização com tamanhos de população diferentes. A função é Maximizar $f(x) = x \cdot \sin(10 \cdot \pi \cdot x) + 1$ sujeito a seguinte restrição $-10 \leq X \leq 20$. Os tamanhos das populações aplicados são: 20, 100 e 1000. O parâmetro de numero de gerações foi fixado em 100. O método de seleção escolhido foi Torneio de 2, o tipo de cruzamento aplicado foi de 1 ponto com corte no meio do cromossomo com 90% de probabilidade de ocorrência. O tipo de mutação aplicado foi por inversão com 1% de probabilidade de ocorrência.

No algoritmo proposto foram determinados ainda outros parâmetros. Para probabilidade de inseminação foi definida 30% a 50%. Para probabilidade de cruzamento 90% a 70% e para probabilidade de mutação 1% a 5%. Vale ressaltar que o método proposto é dinâmico e com isso ele verificar a evolução do algoritmo para alterar os parâmetros dentro de seu intervalo.

A codificação do algoritmo aplicada é binária. Todos os parâmetros foram definidos por teste preliminares que não serão relatados nesse documento. Esses testes foram determinantes para definir a melhor eficiência do algoritmo em relação aos métodos de seleção tipo de cruzamento e mutação.

A Figura 9 ilustra os testes realizados com os dois algoritmos com a população de tamanho 20. Nesse teste foi utilizada a mesma população inicial em todos os cenários. Sendo os resultados estabelecidos pela média de 4 simulações.

Comparação de resultados de caso 1			
Maximizar $f(x) = x \cdot \sin(10 \cdot \pi \cdot x) + 1$		Sujeito a: $-10 \leq X \leq 20$	
Codificação do cromossomo	Binária	Tamanho da população	20
Máximo de gerações	100	Método de seleção	Torneio de 2
Método de Cruzamento	1 ponto	Método de mutação	Inversão
Parâmetros do Algoritmo Tradicional		Parâmetros do Algoritmo Proposto	
Probabilidade de cruz.	90%	Probabilidade de cruz.	90% a 70%
Probabilidade de mut.	1%	Probabilidade de mut.	1% a 5%
		Probabilidade de ins.	30% a 50%
Solução Elite Inicial:	15,7178	Solução Elite Inicial:	15,7178
Solução Elite Final:	20,6105	Solução Elite Final:	20,5317
Solução Elite Final:	19,0952	Solução Elite Final:	20,4425
Solução Elite Final:	20,6361	Solução Elite Final:	20,5231
Solução Elite Final:	18,0907	Solução Elite Final:	20,8554
Média das soluções elites:	19,6081	Média das soluções elites:	20,5882

Figura 9: Comparação para população de tamanho 20.

Ainda analisando a Figura 9, podemos observar as seguintes informações. Maior valor encontrado 20,85 sendo esse no algoritmo proposto, melhor média de resultados 20,58, também no algoritmo proposto.

A Figura 10 ilustra os resultados dos testes aplicados a uma nova população com 100 cromossomos. É importante ressaltar que nesses testes foram utilizados os mesmos parâmetros do teste apresentado na Figura 9. Note que a média final foi cerca de 5% maior no algoritmo proposto nesse documento.

Em análise a esses testes observa-se que o aumento na população foi primordial para melhora nos resultados. Desde a população inicial até a população final, os valores dos cromossomos elite foram superiores aos encontrados nos testes aplicados com a população de 20 indivíduos.

Em relação aos novos resultados o algoritmo proposto novamente se comportou melhor, apresentando a melhor média 20,82 e o maior valor absoluto 20,85. Comparando com a média do algoritmo tradicional que foi de 20,36 é possível verificar que a eficiência do mesmo foi de 2,2% superior no algoritmo proposto e no melhor valor absoluto encontrado de 1,2% superior.

Comparação de resultados do estudo de caso 1			
Maximizar $f(x) = x \cdot \text{seno}(10 \cdot \text{PI} \cdot x) + 1$		Sujeito a: $-10 \leq X \leq 20$	
Codificação do cromossomo	Binária	Tamanho da população	100
Máximo de gerações	100	Método de seleção	Torneio de 2
Método de Cruzamento	1 ponto	Método de mutação	Inversão
Parametros do Algoritmo Tradicional		Parametros do Algoritmo Proposto	
Probabilidade de cruz.	90%	Probabilidade de cruz.	90% a 70%
Probabilidade de mut.	1%	Probabilidade de mut.	1% a 5%
		Probabilidade de ins.	30% a 50%
Solução Elite Inicial:	18,5834	Solução Elite Inicial:	18,5834
Solução Elite Final:	20,5850	Solução Elite Final:	20,8499
Solução Elite Final:	20,2422	Solução Elite Final:	20,7399
Solução Elite Final:	20,0417	Solução Elite Final:	20,8592
Solução Elite Final:	20,6080	Solução Elite Final:	20,8498
Média das soluções elites:	20,3692	Média das soluções elites:	20,8247

Figura 10: Comparação para população de tamanho 100.

Continuando os testes, foi aplicado um novo teste com tamanho de população de 1000 cromossomos. Nesses testes também foi considerado o tempo de execução do algoritmo, pois como a população tornou-se ligeiramente grande, começa a ser necessário verificar a eficiência em relação ao tempo de execução.

A Figura 11 ilustra o teste com população de 1000 cromossomos. Novamente a média dos resultados voltou a subir em ambos os algoritmos com o aumento da população. A eficiência do algoritmo proposto foi inferior a 1%. Já o tempo de execução foi 13% melhor no algoritmo proposto. A eficiência do resultado nesse caso não foi tão superior devido a simplicidade da aplicação do algoritmo, entretanto o algoritmo proposto se mostrou mais eficiente, mesmo sendo pequena a diferença.

Comparação de resultados de caso 1			
Maximizar $f(x) = x \cdot \text{seno}(10 \cdot \text{PI} \cdot x) + 1$		Sujeito a: $-10 \leq X \leq 20$	
Codificação do cromossomo	Binária	Tamanho da população	1000
Máximo de gerações	100	Método de seleção	Torneio de 2
Método de Cruzamento	1 ponto	Método de mutação	Inversão
Parametros do Algoritmo Tradicional		Parametros do Algoritmo Proposto	
Probabilidade de cruz.	90%	Probabilidade de cruz.	90% a 70%
Probabilidade de mut.	1%	Probabilidade de mut.	1% a 5%
		Probabilidade de ins.	30% a 50%
Solução Elite Inicial:	Resultado 20,3477	Solução Elite Inicial:	Resultado 20,3477
Solução Elite Final:	20,8494 Tempo(s) 8,753	Solução Elite Final:	20,8499 Tempo(s) 7,501
Solução Elite Final:	20,6500 8,653	Solução Elite Final:	20,8500 7,731
Solução Elite Final:	20,8431 8,492	Solução Elite Final:	20,8499 7,541
Solução Elite Final:	20,8489 8,502	Solução Elite Final:	20,8592 7,461
Média das soluções elites:	20,7979 8,600	Média das soluções elites:	20,8523 7,559

Figura 11: Comparação para população de tamanho 1000.

4.2. Estudo de Caso 2

Para o segundo estudo de caso, foi aplicada uma função de maximização com dois objetivos e com tamanhos de população diferentes. As funções são Minimizar $f(x) = x^2 - 3x + 4$ e Maximizar $f(x) = x * \sin(10 * \pi * x) + 1$ sujeitas a seguinte restrição $-5 \leq X \leq 5$. Os tamanhos das populações aplicados são: 20 e 100.

Os demais parâmetros utilizados são os mesmos aplicados no primeiro estudo de caso. O peso utilizado em cada uma das funções foi de 50%. Nesse caso é possível dizer que estamos tratando de um problema bi-objetivo.

A Figura 12 ilustra os resultados obtidos nos testes realizados nesse problema. Nesse novo estudo de caso, os resultados obtidos foram novamente superiores no algoritmo proposto. Como o problema é de pequeno porte a eficiência notada não é tão grande em uma população grande, porém as melhores médias e os melhores valores absolutos encontrados foram identificados no algoritmo proposto.

Novamente com a população maior os dois algoritmos obtiveram resultados melhores, sendo que o algoritmo proposto obteve o maior valor absoluto (0,4987) e a melhor média (0,4981) nos dois testes. No primeiro teste a eficiência nas médias foi superior a 9%, já no segundo teste foi de 3%.

Comparação de resultados do estudo de caso 2			
Maximizar $f(x) = x * \text{seno}(10 * \pi * x) + 1$	Minimizar $f(x) = x^2 - 3x + 4$	Sujeito a: $-5 \leq X \leq 5$	
Codificação do cromossomo	Binária	Tamanho da população	20
Máximo de gerações	100	Método de seleção	Torneio de 2
Método de Cruzamento	1 ponto	Método de mutação	Inversão
Parâmetros do Algoritmo Tradicional		Parâmetros do Algoritmo Proposto	
Probabilidade de cruz.	90%	Probabilidade de cruz.	90% a 70%
Probabilidade de mut.	1%	Probabilidade de mut.	1% a 5%
		Probabilidade de ins.	30% a 50%
Solução Elite Inicial: 0,2585		Solução Elite Inicial: 0,2585	
Solução Elite Final: 0,4683		Solução Elite Final: 0,4880	
Solução Elite Final: 0,4115		Solução Elite Final: 0,4963	
Solução Elite Final: 0,4361		Solução Elite Final: 0,4983	
Solução Elite Final: 0,4773		Solução Elite Final: 0,4751	
Média das soluções elites: 0,4483		Média das soluções elites: 0,4894	
Comparação de resultados de caso 2			
Maximizar $f(x) = x * \text{seno}(10 * \pi * x) + 1$	Minimizar $f(x) = x^2 - 3x + 4$	Sujeito a: $-5 \leq X \leq 5$	
Codificação do cromossomo	Binária	Tamanho da população	100
Máximo de gerações	100	Método de seleção	Torneio de 2
Método de Cruzamento	1 ponto	Método de mutação	Inversão
Parâmetros do Algoritmo Tradicional		Parâmetros do Algoritmo Proposto	
Probabilidade de cruz.	90%	Probabilidade de cruz.	90% a 70%
Probabilidade de mut.	1%	Probabilidade de mut.	1% a 5%
		Probabilidade de ins.	30% a 50%
Solução Elite Inicial: 0,3499		Solução Elite Inicial: 0,3499	
Solução Elite Final: 0,4985		Solução Elite Final: 0,4987	
Solução Elite Final: 0,4887		Solução Elite Final: 0,4987	
Solução Elite Final: 0,4442		Solução Elite Final: 0,4963	
Solução Elite Final: 0,4986		Solução Elite Final: 0,4987	
Média das soluções elites: 0,4825		Média das soluções elites: 0,4981	

Figura 12: Comparação para população de tamanho 20 e 100.

5. Conclusões e perspectivas

Observou-se nos resultados que houve uma redução significativa da aleatoriedade das soluções, fazendo com que o algoritmo convergisse mais adequadamente, também foi possível observar que o dinamismo nos parâmetros reduziu a convergência estagnada para mínimos locais. Assim o algoritmo não permaneceu estagnado nesses pontos.

O algoritmo proposto apresentou resultados satisfatórios em relação ao algoritmo genético sem aplicação de inseminação artificial, o mesmo demonstrou-se mais rápido na maioria dos casos e sempre mais eficientes nos casos estudados e aplicados.

Novas aplicações com um e vários objetivos estão sendo testadas para validação desse novo algoritmo proposto nesse documento. Também pretende-se realizar comparações com problemas clássicos já estudados e apresentados na literatura referente aos algoritmos genéticos.

Entende-se que os estudos representam uma boa contribuição para outras pesquisas em algoritmos evolutivos, mais especificadamente em algoritmos genéticos.

As perspectivas para os estudos são a aplicação dessa técnica em alguns problemas mais complexos e com múltiplos objetivos, nota-se que nos pequenos problemas as respostas foram consideradas boas.

Espera-se que os mesmos resultados possam ser alcançados em aplicações mais complexas, podendo assim generalizar a técnica a incorporar como um eficiente recurso aos estudos de AG's.

Referências

Fogel, L. (1962). *Autonomus automata*. Industrial Research, v. 4, n. 1, 14–19.

Goldberg, D. E. (1989) *Genetic algorithms in search, optimization, and machine learning*. New York: Addison-Wesley.

Linden, R. (2008). *Algoritmos Genéticos*. Editora BRASPORT, Rio de Janeiro.

Mangano, S. (1995). *Computer Design*, May.

Varela, M. L. R. (2007) *Uma Contribuição para o Escalonamento da Produção Baseado em Métodos Globalmente Distribuídos*. Tese (Doutorado em Engenharia de Produção e Sistemas) – Minho – PT, Universidade do Minho – Portugal.