



UEPB

**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS VII
CENTRO CIÊNCIAS EXATAS E SOCIAIS APLICADAS – CCEA
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

LUCAS VALE FAUSTINO DA SILVA

**ALGORITMO GENÉTICO COM SELEÇÃO SEXUAL NA RESOLUÇÃO DE PROBLEMAS
DE OTIMIZAÇÃO**

**PATOS
2017**

LUCAS VALE FAUSTINO DA SILVA

**ALGORIMO GENÉTICO COM SELEÇÃO SEXUAL NA RESULUÇÃO DE PROBLEMAS
DE OTIMIZAÇÃO**

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Ciência da Computação da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de Graduado em Bacharelado em Ciência da Computação.

Área de concentração: Algoritmos Evolutivos.

Orientador: Prof. Dr. Wellington Candeia de Araujo.

**PATOS
2017**

Lucas Vale Faustino da Silva

**ALGORITMO GENÉTICO COM SELEÇÃO SEXUAL PARA RESOLUÇÃO DE
PROBLEMAS DE OTIMIZAÇÃO**

Trabalho de Conclusão de Curso apresentado ao
Curso de Bacharelado em Computação da
Universidade Estadual da Paraíba, em
cumprimento à exigência para obtenção do grau
de Bacharel em Ciência da Computação

Aprovado em 22 de fevereiro de 2017

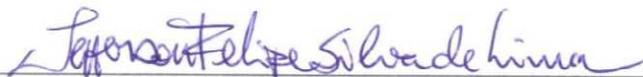
BANCA EXAMINADORA



Wellington Candeia de Araujo
(Orientador)



Alanna Camylla Coêlho Monteiro
(Examinadora)



Jefferson Felipe Silva de Lima
(Examinador)

É expressamente proibida a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano da dissertação.

S586a Silva, Lucas Vale Faustino da
Algoritmo Genético com seleção sexual para resolução de
problemas de otimização [manuscrito] / Lucas Vale Faustino da
Silva. - 2017.
22 p. : il. color.

Digitado.
Trabalho de Conclusão de Curso (Graduação em Computação)
- Universidade Estadual da Paraíba, Centro de Ciências Exatas e
Sociais Aplicadas, 2017.
"Orientação: Prof. Dr. Wellington Candeia de Araujo,
CCEA".

1. Algoritmos Genéticos. 2. Otimização em Algoritmos. 3.
Variância. 4. Seleção Sexual em Algoritmos. I. Título.
21. ed. CDD 005.3

ALGORITMO GENÉTICO COM SELEÇÃO SEXUAL NA RESOLUÇÃO DE PROBLEMAS DE OTIMIZAÇÃO

Lucas Vale Faustino da Silva¹

RESUMO

Algoritmos Genéticos-AG têm problemas muito conhecidos pela literatura, principalmente no que diz respeito a falta de variabilidade genética ao longo das gerações, ou seja, o algoritmo converge prematuramente para soluções subótimas mas também podemos identificar uma alta variância quanto a solução encontrada após várias execuções. Um algoritmo genético clássico executado em um espaço de busca simples tende a alcançar um padrão de soluções simples onde os descendentes são muito semelhantes aos seus pais. Esta limitação faz com que os algoritmos genéticos tenham um desempenho abaixo dos demais algoritmos baseados em heurísticas. Uma tentativa de resolver esse problema é implementar a seleção sexual, descrita por Darwin no livro A Origem das Espécies, como forma de melhorar seu desempenho na tentativa de encontrar o ótimo desejado, mas também melhorar a sua variância quanto a solução encontrada ao fim de várias execuções.

Palavras-Chave: Algoritmos Genéticos, otimização, variância, seleção sexual.

1. INTRODUÇÃO

Algoritmos evolutivos (AE) constituem uma família de métodos estocásticos de busca, baseados em mecanismos de evolução biológica. A motivação de construção de modelos computacionais surgiu através das teorias de que a natureza, por meio de seus recursos, resolve problemas de alta complexidade, isto é, a partir de uma determinada quantidade de recursos é capaz de solucionar problemas, como por exemplo, encontrar alimentos em um ambiente hostil e até mesmo escasso.

AE são capazes de solucionar de forma satisfatória problemas complexos de multiobjectivos, pois possuem como grande vantagem de alcançar ótimos globais em funções com alto grau de complexidade sem o uso de métodos determinísticos. Por tal motivo, a realização de pesquisas por cientistas e pesquisadores de computação, a fim de, encontrar alternativas para melhorar a resolução de tais problemas se tornam cada vez mais recorrente na academia e na indústria.

Algoritmos Genéticos (AG) são uma classe de algoritmos evolucionários de busca baseados em princípios de seleção natural e em princípios genéticos. Tais princípios

¹ Aluno de Graduação em Ciência da Computação na Universidade Estadual da Paraíba – Campus VII.
Email: valelucas1@gmail.com

encontrados na teoria da evolução, tornam o AG um eficiente modelo computacional para busca de soluções em problemas de otimização através da simulação de processos evolutivos Goldberg, (1989).

Além disso o AG base tem problemas conhecidos como a falta de variabilidade genética dos cromossomos durante as iterações, bem como, o alto desvio padrão encontrado durante as execuções do algoritmo e também tende a ficar preso em um mínimo local, muitas vezes por motivos citados anteriormente. Como forma de contornar essas limitações, foi introduzido, neste trabalho, novo operador genético, a seleção sexual. A seleção sexual justifica-se por ser uma característica presente na teoria da evolução que não é levada em conta no algoritmo genético convencional.

A seleção sexual não depende da disputa com existência de outros seres organizados, ou as condições do ambiente, mas da competição entre indivíduos de um sexo, primariamente machos, para assegurar a posse do outro sexo Darwin,(1859). A seleção sexual é menos rigorosa que a seleção natural, pois diferente, do que acontece com a seleção natural a seleção sexual não leva em consideração as pressões exercidas pelo ambiente, mas sim um fator de atração que está ligado a cada indivíduo, neste caso, os machos podendo assim gerar novas características e por fim uma maior diversidade.

Tendo isso em vista o que foi colocado, a proposta é usar modelo de seleção sexual como um fator não necessariamente determinístico visando uma maior variabilidade genética entre os indivíduos de uma determinada população, podendo assim, ajudar a solucionar os problemas antes citados.

2. IMPORTÂNCIA DA SELEÇÃO SEXUAL

A seleção sexual foi vista por muitas vezes como uma característica intrínseca a seleção natural e em grande parte irrelevante para as questões centrais na biologia, entre elas, a especiação, diversidade entre os indivíduos, e adaptações complexas Cronin, (1991). Mas essa visão tradicional parece não refletir a realidade já que podemos observar o fato de que a taxa mais complexa, diversificada e elaborada na terra advém da escolha de um companheiro. Uma característica comum aos animais e as plantas é que ambos experimentam algum tipo de seleção sexual na escolha do indivíduo ao qual irão relacionar-se, ou seja, seu companheiro Cronin (1991), Darwin (1871).

Nos últimos 20 anos tem havido uma grande expansão de trabalhos usando a seleção sexual através da escolha do companheiro. Experimentos comportamentais em animais mostraram que as fêmeas de muitas espécies apresentaram fortes preferências

por determinadas características presentes nos machos Catchpole (1980). Modelos evolutivos simulados em computador mostraram a legitimidade, robustez e poder de seleção sexual aleatória Todd & Miller (1993).

Tendo em vista, a seleção sexual passou a ser um fator importante no entendimento de como as populações desenvolvem indivíduos complexos e adaptados, uma forma de entender esse desenvolvimento foi proposto por Eldredge (1985); (1986), que desenvolveu um modelo geral da evolução baseado numa hierarquia genealógica, compostos por genes, organismos, espécies entre outros. Os fenótipos nesse ponto de vista são compostos por duas características específicas: “Características econômicas”, que estão ligadas diretamente a seleção natural com a hierarquia ecológica e “características evolutivas” que estão ligadas a seleção sexual para lidar com outras entidades, por exemplo, parceiros em potencial. Eldredge (1989) enfatiza que as relações entre o sucesso econômico e o sucesso evolutivo podem ser bem fracas e que essas relações podem inclusivamente não ser tão favorável a otimização geral. Em contrapartida não desconsidera a possibilidade de haver uma evolução dinâmica que ocorre dentro da hierarquia ecológica. Assim, mesmo em sua revisão totalitária da teoria macro evolutiva Eldredge(1989) tem dado espaço para a possibilidade autônoma e adaptativa da seleção sexual e a interação adaptativa, a fim de melhorar a evolução, entre a seleção sexual e a seleção natural.

Se observamos a seleção natural resulta em uma evolução convergente para ótimos locais dado o conhecimento de um determinado local. Na seleção natural os organismos se adaptam a ambientes baseados no seu fator de adaptabilidade ou ao quão adaptados estão á aquele ambiente, portanto, baseando-se no fato de que esses indivíduos se adaptam a determinados ambientes a seleção natural pode ser vista analogamente como um processo de subida da encosta, muito bom para picos adaptativos mas demonstra falhas nas tentativas de descobrir novos picos.

Em contrapartida, a seleção sexual resulta em um padrão imprevisível, divergente da seleção natural, com especiações espontâneas surgindo a partir da exploração de novas possibilidades fenotípicas de acordo com as preferências ligadas a atração sexual. Na seleção sexual, o “ambiente” ou espaço de busca, são constituídos pela escolha do melhor parceiro naquele momento, em diversas vezes, momento de fertilidade da fêmea, já que é ela, na maioria dos casos, a responsável por tal escolha. Assim o ambiente e as adaptações podem co-evoluir sob a seleção sexual como Fisher (1930), percebeu em seus trabalhos.

3. ALGORITMO GÉNÉTICO PADRÃO

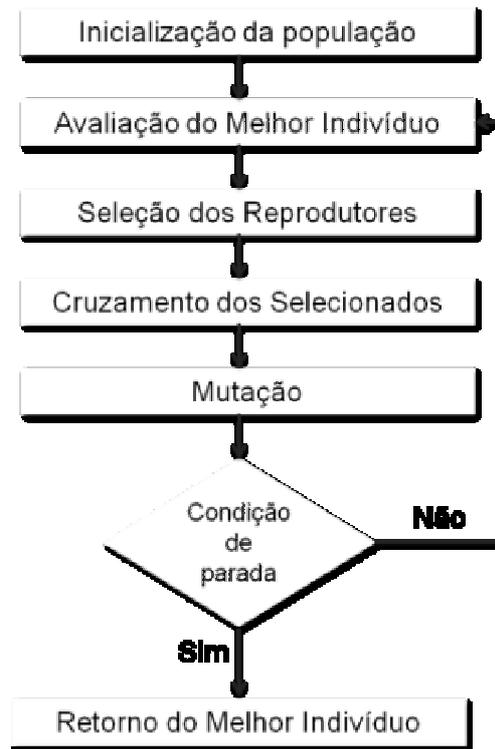
Algoritmos Genéticos são uma técnica de otimização baseada numa metáfora de processos biológicos e genéticos da evolução natural. Os algoritmos genéticos são técnicas de heurísticas de otimização global. Seguindo a ideia de evolução nos algoritmos genéticos uma determinada população de indivíduos é sujeita a determinados operadores genéticos: seleção, *crossover* e mutação. Esses operadores usam uma característica baseada no nível de adaptação do indivíduo em relação ao ambiente ao qual os mesmos estão inseridos, para entender melhor como se dá essa evolução podemos resumi-las nos seguintes passos:

1. Inicialmente escolhe-se uma população inicial de indivíduos normalmente aleatória;
2. Avalia-se toda a população de indivíduos, a partir de algum critério, normalmente uma função (“*fitness*”) matemática ligada ao domínio do problema, onde cada indivíduo é avaliado a partir de sua qualidade;
3. Por conseguinte, selecionam-se os melhores indivíduos através do operador de seleção que servirá como base para a criação de um novo conjunto de possíveis soluções, ou seja, a nova população;
4. Esta nova população é obtida através do operador de cruzamento entre os indivíduos selecionados anteriormente e este cruzamento (“*crossover*”) se dá através da combinação de genes entre os indivíduos selecionados, usualmente dois;
5. Após a geração da nova população é aplicado o operador de mutação, onde um indivíduo na nova população é escolhido aleatoriamente e suas características são alteradas de forma também aleatória;

Esses passos são repetidos até que a condição de parada seja aceita, geralmente a otimização seja concluída, ou através de uma quantidade de iterações definida inicialmente.

A Imagem 1 demonstra através de um fluxograma o funcionamento do Algoritmo Genético Padrão:

Figura 1: Fluxograma do Algoritmo Genético



Fonte: Elaborado pelo autor

4. ALGORITMO GÉNÉTICO E SELEÇÃO SEXUAL

O novo algoritmo proposto introduz diversas modificações em relação ao algoritmo genético base apresentado em Goldberg (1989). Seguindo a ordem de como se dá o algoritmo genético serão detalhadas como essas modificações são implementadas.

A. População inicial

A população inicial se dá de forma parecida ao algoritmo genético base, onde, a população é escolhida de forma aleatória sendo levado em consideração o domínio do problema, para esta fase do AG propusemos duas mudanças quanto a formação da população inicial.

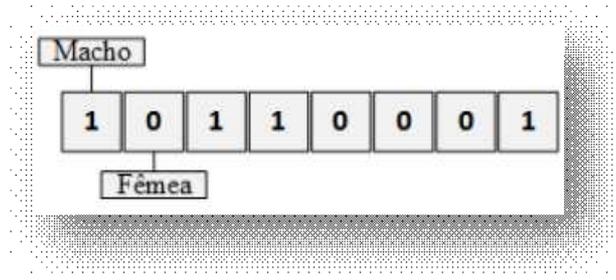
B. Definição do sexo

Cada indivíduo a partir de agora também estará contido em suas características a sua sexualidade. Esta sexualidade se dividirá entre macho e fêmea:

- Macho será identificado no algoritmo pelo uso do bit 1;
- Fêmea será identificada no algoritmo pelo uso do bit 0;

Dessa forma podemos visualizar melhor como ficará essa representação em um vetor de machos e fêmeas na Fig. 2.

Figura 2: Fluxograma do algoritmo vagalume modificado



Fonte: Elaborado pelo autor

C. Definição do fator de atratividade

Esse valor será necessário para estabelecer a seleção de forma sexual, ou seja, os indivíduos com maior valor de atração serão escolhidos quando houver seleção sexual.

Em sua teoria Darwin propôs que a atratividade da fêmea não se dava apenas por fatores de pressão de ambiente, mas também, por características físicas que poderiam ser atrativas ao sexo feminino. Darwin propôs que a competição reprodutiva entre homens como uma explicação para evolução das estruturas limitadas entre homens. Ou seja, a sua proposta se baseia em como características exageradas tem sido identificadas em maior número entre macho do que em fêmeas.

Seleção Sexual Darwiniana é responsável por dois padrões em natureza: (1) os machos e fêmeas da mesma espécie diferem um do outro; e, (2) os machos de espécies estreitamente relacionadas tendem a ser muito mais diferentes uns dos outros em termos de estrutura e comportamento do que as fêmeas. Para representar a atratividade proposta nesse trabalho, levaremos em consideração, as diferenças estruturais físicas entre os sexos, quanto maior essa diferença, maior será a probabilidade, e por consequência a atratividade, de um macho ser escolhido por uma determinada fêmea no processo de seleção sexual.

Para avaliar a afinidade entre a fêmea e os machos, ou o grau de ligação, entre os indivíduos selecionados na seleção sexual, utilizaremos dois tipos de distâncias. Matematicamente a atratividade entre uma fêmea e um macho está relacionada a distância entre eles, que pode ser estimada através de qualquer medida de distância (similaridade) entre (os vetores utilizados para representar) o macho e a fêmea, como por exemplo, a distância Euclidiana, usada para medir a distância ou a similaridade em representações

numéricas e distância de Hamming, usada para medir a distância ou a similaridade em representações binárias.

Na distância Euclidiana, se as coordenadas do macho forem dadas por **macho** = (x_1, x_2, \dots, x_n) e as coordenadas da fêmea forem dadas por **femea** = (x_1, x_2, \dots, x_n) , então a distância D entre esses dois cromossomos pode ser medida pela Equação (1):

$$D = \sqrt{\sum_{i=1}^n (\mathbf{femea}(x_i) - \mathbf{macho}(x_i))^2} \quad (1)$$

No caso da distância de Hamming, se as coordenadas do macho forem dadas, por exemplo, macho=(1,0,1,0,1) e as coordenadas da fêmea forem dadas, por exemplo, femea=(0,0,1,0,1), então a distância D entre esses dois cromossomos pode ser medida pela Equação (2):

$$D = \sum_{i=1}^n \delta_i, \text{ onde } \delta = \begin{cases} 1 & \text{se } \mathbf{macho}(i) \neq \mathbf{femea}(i) \\ 0 & \text{outros casos} \end{cases} \quad (2)$$

D. Cruzamento

O cruzamento se dará também de forma parecida ao que encontramos no GA base, apenas levaremos em consideração agora as duas modificações expostas anteriormente, a atratividade e a sexualidade, ou seja, a partir de agora além de cruzarmos os dois indivíduos levando em consideração apenas o vetor de genes, teremos que levar essas duas novas características na hora do cruzamento.

Após a seleção dos dois indivíduos, a fase de cruzamento também levará em consideração o fator de atração ao cruzar os dois indivíduos. Este cruzamento dependerá de qual tipo de representação foi utilizada para representar esta característica.

Na representação binária podemos ter diversas formas de cruzamento, todas essas, já apresentadas no GA base, como por exemplo, cruzamento de um ponto, cruzamento de dois pontos e cruzamento uniforme que podem ser encontradas em *Goldberg (1989)*. O mesmo ocorre na representação numérica, podemos encontrar diversas formas de realizar este cruzamento, entre eles temos, o cruzamento aritmético, cruzamento *flat* que podem ser encontradas em *Goldberg (1989)*.

E. Seleção sexual

Na natureza a seleção sexual parece não se apresentar de forma padronizada, ou seja, a seleção sexual não se define como um padrão que pode ser encontrado nos mais diversos ambientes da natureza, bem como, nas relações entre machos e fêmeas.

Devido a tal diversidade, assim como, na dificuldade de representa-la de forma concisa e genérica, este trabalho propõe uma forma simples de simulação de como a natureza concilia a seleção natural, como forma de sobrevivência e repasse das características mais bem adaptadas para os seus descendentes, do mesmo modo que, a seleção sexual atua como forma diversificadora dentro de uma população de uma determinada espécie. Atuando de forma conjunta a seleção natural e a seleção sexual podem apresentar resultados melhores na sobrevivência das espécies, e no âmbito, de algoritmos meta heurísticos essas características podem levar uma otimização mais contundente no fim de sua execução.

Uma nova característica agora será levada em consideração, a probabilidade de seleção sexual, que pode variar de acordo com as necessidades e pressão do ambiente, esse fator será determinante para decidirmos se haverá seleção sexual ou seleção natural. No trabalho proposto iremos iniciar nossa pesquisa com uma taxa de probabilidade de seleção sexual fixa em 10, 20 e 30% ou seja, em 10,20 ou 30% dos casos gerais de seleção poderá ocorrer a seleção sexual.

Caso a seleção sexual ocorra, o que será levado em consideração para a escolha de quais cromossomos participarão da fase de cruzamento será a maior atratividade de um determinado macho em relação a fêmea, ou seja, dois machos disputarão entre si a “atenção” da fêmea (atratividade), que será calculada, utilizando das funções descritas anteriormente. A fêmea é selecionada utilizando técnicas de seleção natural, neste trabalho, a seleção por torneio, após a seleção da fêmea os machos serão selecionados de forma aleatória e a sua atratividade em relação a fêmea selecionada será calculado. O macho com maior atratividade será selecionado cruzara com a fêmea na fase de cruzamento.

Este processo de sorteio percentual para escolha de seleção natural ou seleção sexual se estenderá até a formação de uma nova população a cada geração, ou seja, a cada geração, os machos e fêmeas poderão ser escolhidos para fase de cruzamento tanto pela seleção sexual, caso o caso de teste percentual seja atingido, tanto pela seleção natural. Ao fim da fase de seleção os machos e fêmeas, que provavelmente serão selecionados pelos dois processos seleção, passarão para a fase de cruzamento, onde ao fim, se dará o

termino desta proposta de trabalho, daí em diante, dá-se a continuidade das fases já descritas no AG Base. Para entender melhor como se dá essas mudanças podemos resumilas nos seguintes passos:

1. Inicialmente escolhe-se uma população inicial de indivíduos com distribuição aleatória;
2. Define-se o sexo de cada cromossomo;
3. Avalia-se toda a população de indivíduos, a partir de algum critério, normalmente uma função matemática ligada ao domínio do problema, onde cada indivíduo é avaliado a partir de sua qualidade (“*fitness*”);
4. A cada geração de novos cromossomos dá-se o seguinte processo:
 - 4.1. Testa se a probabilidade de seleção sexual é aceita, se não, ocorre a seleção natural como já acontece no GA padrão;
 - 4.2. Caso a seleção sexual ocorra, uma fêmea é selecionada utilizando o método de seleção tradicional.
 - 4.3. Dois machos são selecionados de forma aleatória e suas respectivas atratividades em relação a fêmea selecionada no passo anterior serão calculadas;
 - 4.4. O macho com maior atratividade é selecionado para fase de cruzamento;
 - 4.5. Caso a seleção sexual não ocorra, a fêmea bem como o macho serão selecionados pela estratégia de seleção natural;
 - 4.6. O macho e a fêmea selecionados, tanto por seleção sexual caso ocorra quanto por seleção natural, passarão para fase de cruzamento (“crossover”), onde será realizado a combinação de genes entre os cromossomos selecionados;
 - 4.7. Os passos do Item 4 se repetirá até a formação da nova população;
5. Após a geração da nova população é aplicado o operador de mutação, onde um indivíduo na nova população é escolhido aleatoriamente e suas características são alteradas de forma aleatória;
6. Esses passos são repetidos até que a condição de parada seja aceita, geralmente a otimização seja concluída, ou através de uma quantidade de iterações definida inicialmente.

F. Pseudo-código

Figura 3: Pseudocódigo

```
begin
inicializa os parâmetros
pop ← população inicial (parâmetros)
vetFitness ← avaliaPop(pop)
vetsexo ← definir sexo ()
while(condição)
    contpop=0;
    tampop=length(pop)
    while (contpop!=tampop) do
        se (probseleçãosexual)
            femea=selecionarfemea(pop)
            macho=selecionarmacho(pop)
        else
            femea=selecaonatural(pop)
            macho=selecaonatural(pop)
        endse
        newpop=cruzamento(femea,macho)
        vetFitness ← avaliaPop(pop)
        contpop=contpop+1
    endwhile
pop=newpop
```

Fonte: Elaborado pelo autor

5. EXPERIMENTOS

O Algoritmo Genético e Seleção Sexual (AGSS) tem como base o AG padrão, logo as principais características que são comuns aos dois servirão como base para os testes, como por exemplo, o tamanho da população, a probabilidade de cruzamento entre outros. A principal mudança ocorrerá apenas no AGSS, onde a probabilidade de seleção sexual (μ) será definida de forma empírica em 10, 20 e 30%, com a finalidade de estabelecermos parâmetros de testes iniciais deste trabalho. A Tabela I apresenta as configurações para os testes:

Tabela 1: Configuração para os testes

| Parâmetros | Valores |
|--|------------------|
| Tamanho da população | 100 cromossomos |
| Probabilidade de cruzamento | 90% |
| Critério de parada | 50.000 iterações |
| Número de execuções | 50 |
| Probabilidade de Seleção Sexual(μ) | 10%, 20%, 30% |
| Taxa de mutação | 10% |
| Quantidade de machos | 2 |

Fonte: Elaborado pelo autor

Como pode ser visto na Tabela 1 foram definidos 100 cromossomos como o tamanho da população e 50.000 gerações a cada execução. A probabilidade de cruzamento foi definida em 90% e a taxa de mutação em 10%, essas duas definidas com base no AG Padrão. O número de execuções foi fixado em 50 e serve para indicar o comportamento do algoritmo sendo exposto a diversas execuções, sendo assim, possível avaliar seu desempenho ao longo das mesmas.

5.1. Funções de Teste

Os experimentos foram realizados em funções de minimização multimodais e unimodais, que são amplamente utilizadas pela literatura para medir a eficiência de algoritmos voltados para otimização (JAMIL,2013). A Tabela 2 apresenta as funções de benchmark utilizadas nos testes.

Tabela 2: Funções de Benchmark

| Função | Formula | Dimensões | Valores |
|----------------------|---|-----------|------------|
| Sphere $f(x_1)$ | $f_{sphere} = \sum_i^n 1x_i^2$ | 30 | [-30;30] |
| Ackley $f(x_2)$ | $f_{ackley} = -a \exp\left(-b \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos(cx_i)\right) + a + \exp$ | 30 | [-32;32] |
| Griewank $f(x_3)$ | $f_{griewank} = \frac{1}{4000} \sum_{i=1}^N x_i^2 - \prod_{i=1}^N \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$ | 30 | [-600;600] |
| Schwefel $f(x_4)$ | $f_{schwefel} = -\sum_{i=1}^N (x_i \sin(\sqrt{ x_i }))$ | 30 | [-500;500] |

Fonte: Elaborado pelo autor

6. RESULTADOS E DISCUSSÕES

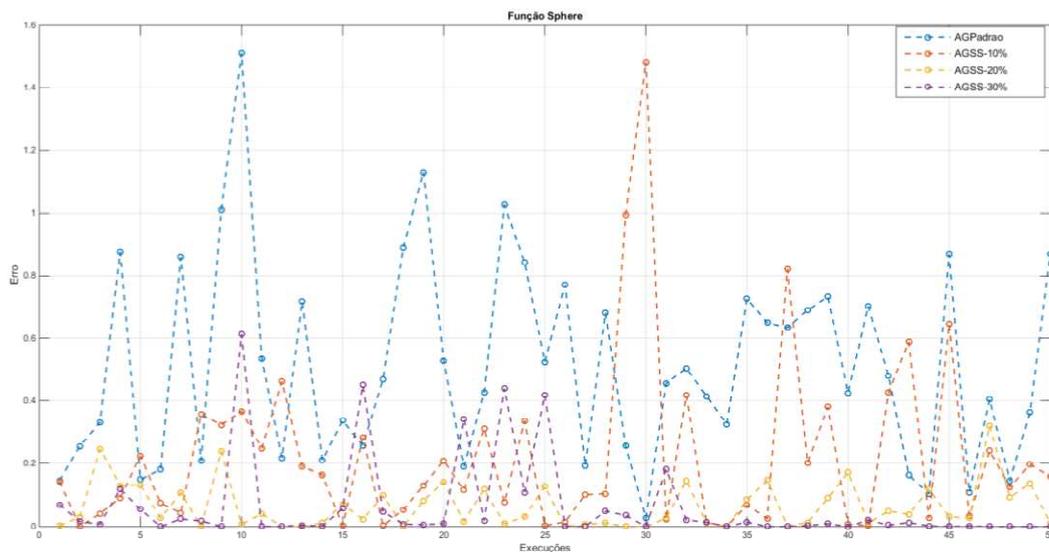
Este experimento tem por objetivo demonstrar os resultados obtidos a partir de testes em funções unimodais e multimodais, que tem por finalidade medir a eficiência de algoritmos em otimização e busca global. Os algoritmos comparados neste trabalho serão: Algoritmo Genético padrão-AG Padrão, proposto por (GOLDBERG,1989) e o algoritmo proposto neste trabalho, o Algoritmo Genético com Seleção Sexual-AGSS.

Uma das formas mais comuns de se avaliar desempenho de algoritmos meta-heurísticos é avaliar os resultados encontrados ao fim de cada execução e demonstrar tais resultados em um gráfico. Como podemos ver na Figura 4 no eixo x temos as execuções e no eixo y temos o erro, quanto menor melhor, que é a distância ou a diferença entre o valor encontrado e o esperado no mínimo da função. Na figura 4 a função em questão é a

Sphere onde o mínimo global pode ser definido como: $f(x) = 0, para x^* = \{0, \dots, 0\}$. Ao analisarmos o eixo x , o eixo das execuções, em relação ao eixo y , o eixo do erro, podemos notar que o AGSS e suas variações quanto probabilidade de seleção sexual apresenta um desempenho melhor que o AG Padrão. O AG Padrão apresenta picos quanto ao resultado encontrado ao fim de diversas execuções, como pode ser visto nas execuções: 4, 7, 10, 19 e 45. Isso acaba comprometendo o desempenho do algoritmo já que ele não consegue manter-se em resultados favoráveis ao fim de cada execução.

Se agora analisarmos o desempenho do AGSS e suas variações de probabilidade, podemos perceber que os mesmos se mantêm sempre o mais próximo possível do mínimo com exceção do AGSS com 10% de probabilidade que apresenta um pico na 30ª execução, mas se observamos no geral, podemos perceber que o algoritmo proposto neste trabalho apresenta um desempenho muito mais satisfatório em relação ao AG Padrão.

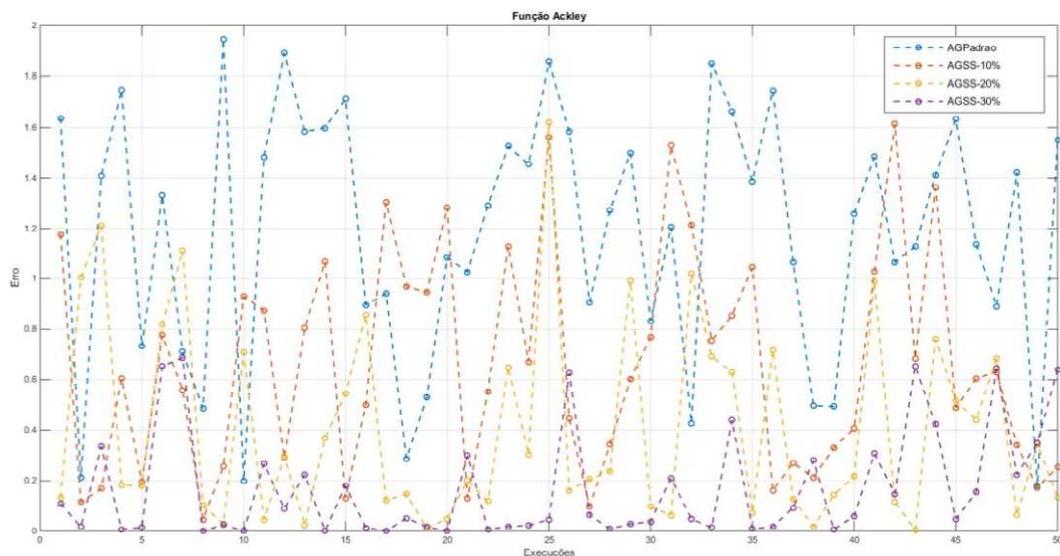
Figura 4: Erro encontrado ao fim de cada execução na função Sphere.



Fonte: Elaborado pelo autor

Seguindo o mesmo experimento demonstrado na Figura 4 e na função Sphere podemos agora analisar os resultados obtidos na função Ackley que são demonstrado na Figura 5. Na figura 5 temos a mesma estrutura, ou seja, podemos ver na Figura 5 no eixo x temos as execuções e no eixo y temos o erro, quanto menor melhor, que é a distância ou a diferença entre o valor encontrado e o esperado no mínimo da função. O mínimo da função Ackley pode ser descrito como: $f(x) = 0, para x^* = \{0, \dots, 0\}$. Ao analisarmos o eixo x , o eixo das execuções, em relação ao eixo y , o eixo do erro, podemos notar que o AGSS e suas variações quanto probabilidade de seleção sexual apresenta um desempenho melhor que o AG Padrão. O AG Padrão apresenta na Figura 5 altos picos quanto aos resultados encontrados ao fim de cada execução, como foi visto anteriormente na função Sphere. Comportamento semelhante ao citado podemos observar no AGSS com probabilidade de seleção de 10% e eventualmente no de 20%, em contrapartida o AGSS com probabilidade de seleção de 30% apresentou resultados satisfatórios mantendo-se, sempre ao fim de cada execução, o mais próximo do mínimo desejável o que atesta a sua capacidade de manter-se sempre que possível próximo de uma solução de otimização aceitável.

Figura 5: Erro encontrado ao fim de cada execução na função Ackley

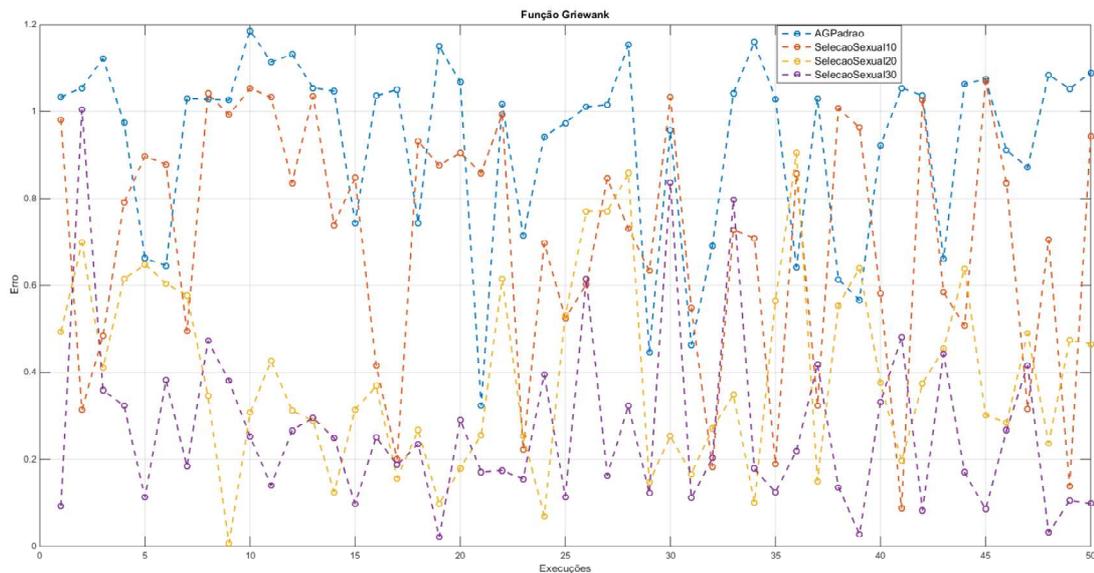


Fonte: Elaborado pelo autor

Seguindo o mesmo experimento demonstrado nas Figura 4 e 5 e nas funções Sphere e Ackley podemos agora analisar os resultados obtidos na função Griewank que são demonstrado na Figura 6. Na figura 6 temos semelhante estrutura, ou seja, podemos ver na Figura 6 no eixo x temos as execuções e no eixo y temos o erro, quanto menor melhor,

que é a distância ou a diferença entre o valor encontrado e o esperado no mínimo da função. O mínimo da função Griewank pode ser descrito como: $f(x) = 0, para x^* = \{0, \dots, 0\}$. Ao analisarmos o eixo x , o eixo das execuções, em relação ao eixo y , o eixo do erro, podemos notar que os resultados obtidos nas funções anteriores foram bem mais satisfatórios do que os obtidos na função Griewank, onde, podemos perceber altos picos tanto no AG Padrão, o que vem se demonstrando de forma repetida nos testes anteriores, bem como no algoritmo proposto neste trabalho. Ao analisarmos a linha do AGSS com probabilidade de 10% podemos perceber que seus resultados estão a todo momento muito próximo dos encontrados no AG Padrão. O mesmo ocorre, mas de forma menos acentuado no AGSS com probabilidade de 20%, onde os picos de mínimos encontrados, encontram-se na maioria das vezes abaixo do AG Padrão. O AGSS com probabilidade de 30%, também apresenta picos mínimos esporádicos o que configura um melhor desempenho em relação aos outros.

Figura 6: Erro encontrado ao fim de cada execução na função Griewank

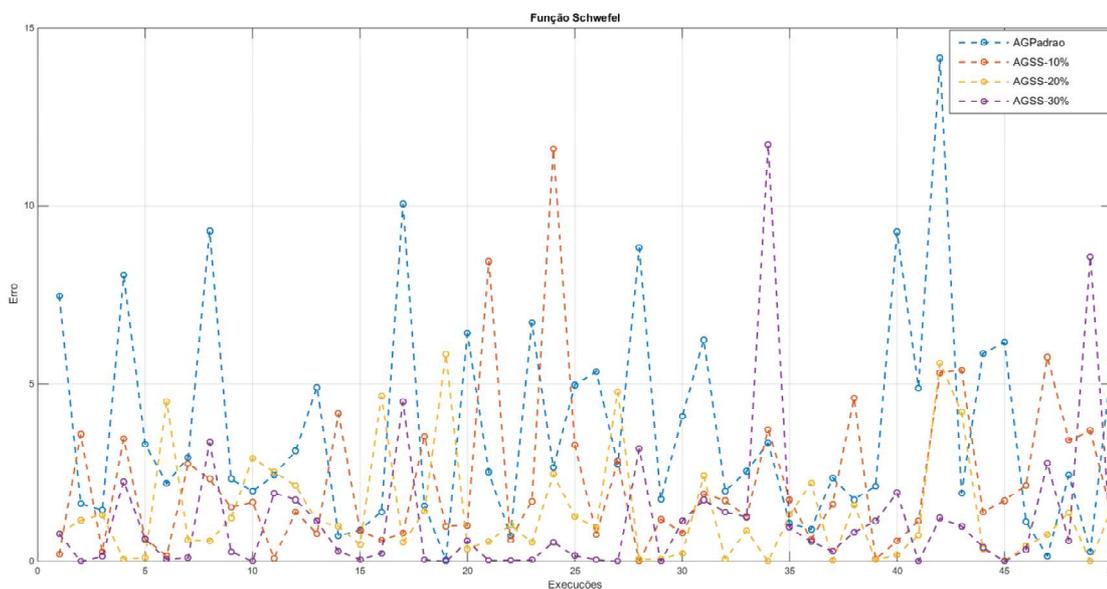


Fonte: Elaborado pelo autor

E por último os resultados obtidos na função Schwefel, que podem ser vistos na Figura 7. O mínimo da função Schwefel pode ser descrito como: $f(x) = 0, para x^* = \{0, \dots, 0\}$. Ao analisarmos o eixo x , o eixo das execuções, em relação ao eixo y , o eixo do erro, podemos notar que os resultados obtidos até então aqui se repetem, o AG Padrão apresenta picos quanto à os valores do erro encontrados ao fim de cada execução. É

importante notar que o AGSS com probabilidade de seleção de 10% e o de 30%, apresentam picos nas execuções 21, 24, 34 e 49 respectivamente o que demonstra um comportamento, do algoritmo proposto neste trabalho, semelhante a os encontrados anteriormente, ou seja, o AGSS e suas variações de probabilidade apresentam resultados em sua grande maioria mais satisfatórios e mais próximo do mínimo desejável do que o AG Padrão, contudo ainda apresenta picos de resultados do valores dos mínimos encontrados ao fim de cada execução.

Figura 7: Erro encontrado ao fim de cada execução na função Schwefel



Fonte: Elaborado pelo autor

Outra forma de analisar os resultados obtidos é analisar o desvio padrão encontrado ao fim das 50 execuções mencionada anteriormente. Ao tecer uma análise sobre desvio padrão, poderemos perceber de forma quantitativa a variedade quanto ao resultado encontrado ao fim das execuções em cada função citada anteriormente. Se observarmos de forma geral podemos perceber que o algoritmo proposto neste trabalho apresenta melhores resultados, quanto menor melhor, diante do AG Padrão.

Ao observarmos cada caso na Tabela 3, podemos perceber que na função Sphere o algoritmo proposto neste trabalho com a probabilidade de seleção sexual de 20% apresentou uma redução de 50% no valor, o que demonstra, que ao executarmos o algoritmo proposto diversas vezes há uma maior chance que alcançar o objetivo desejado. Já na função Ackley os algoritmos demonstraram desempenho similar, tanto o AG Padrão

quanto o AGSS e suas probabilidades demonstraram resultados similares, apenas pontuando o fato de o AGSS com probabilidade de seleção de 30% apresentou uma leve melhora. Na função Griewank o AGSS com probabilidade de seleção de 30%, apresentou o melhor resultado ao compararmos com o AG Padrão, melhora essa de 60%, enquanto as outras variações de probabilidade de seleção sexual também desmontaram melhoras, mas nada muito significativo se compararmos com a melhora citada anteriormente. Na função Schwefel os melhores resultados foram encontrados no Algoritmo proposto, com destaque para o AGSS com probabilidade de 20% que apresentou uma melhora também considerável ao encontrar um desvio de 0.0742, o melhor de todos os testes, assim demonstrando o quão eficaz essa proposta pode ser se compararmos com o AG Padrão.

Tabela 3: Desvio padrão do desempenho das funções benchmark

| Função | AGPadrão | $\mu = 10\%$ | $\mu = 20\%$ | $\mu = 30\%$ |
|----------|----------|--------------|--------------|--------------|
| $f(x_1)$ | 3.0426 | 2.2131 | 1.5266 | 2.1212 |
| $f(x_2)$ | 0.2108 | 0.2880 | 0.2169 | 0.2057 |
| $f(x_3)$ | 0.4940 | 0.4340 | 0.3919 | 0.2155 |
| $f(x_4)$ | 0.3204 | 0.2830 | 0.0742 | 0.1383 |

Fonte: Elaborado pelo autor

Métricas estatísticas como media, pior caso e melhor caso podem também nos demonstrar o desempenho de cada algoritmo ao fim das execuções citadas anteriormente. O pior caso servira como base para avaliar o desempenho quanto ao pior valor encontrado ao fim das execuções, podendo assim demonstrar se seu desempenho é satisfatório. O caso médio é a média encontrada ao fim das 50 execuções, ou seja, ao finalizar os experimentos realizados é salvo o resultado obtido ao fim de cada execução, ao concluir todas as execuções o valor médio é calculado e demonstrado na Tabela 4. O melhor caso segue a mesma lógica dos anteriores, do mesmo modo que, ao fim das execuções o melhor caso para cada função também é exibido na Tabela 4.

O algoritmo proposto neste trabalho, o AGSS e suas probabilidades de seleção, apresentou melhores resultados em todas as funções, com destaque para o AGSS e probabilidade de seleção de 30%, que apresentou resultados ótimos ao calcularmos o melhor caso em todas as funções, mesmo ocorre em todas as variações de probabilidade proposta neste trabalho ao analisarmos a função Schwefel e compararmos com os resultados encontrados no melhor caso do AG Padrão.

Ao analisarmos o pior caso, podemos observar que nas funções Sphere, Griewank e Schwefel o AGSS e suas probabilidades de seleção apresentou resultados satisfatórios se comparado com o AG Padrão, contudo o mesmo não ocorre com a mesma eficácia na função Ackley, onde os resultados encontrados para o pior caso são muito semelhantes, quase não demonstrando uma melhora significativa.

Tabela 4: Pior, Média, Melhor encontrado em cada algoritmo.

| F | | $f(x_1)$ | $f(x_2)$ | $f(x_3)$ | $f(x_4)$ | |
|-----------------------------|---------------|---------------|-------------|----------|------------|-----------|
| AG Padrão | Pior | 1.5108 | 1.1854 | 1.9462 | 14.1433 | |
| | Média | 0.5105 | 0.9302 | 1.1837 | 3.7358 | |
| | Melhor | 0.0270 | 0.3235 | 0.1797 | 0.0549 | |
| Algoritmo Modificado | $\mu = 10\%$ | Pior | 1.4834 | 1.0691 | 1.6142 | 11.5844 |
| | | Média | 0.2271 | 0.7040 | 0.6654 | 2.2261 |
| | | Melhor | 7.91191e-06 | 0.0870 | 0.0459 | 0.0189 |
| | $\mu = 20\%$ | Pior | 0.3203 | 0.9045 | 1.6195 | 5.8316 |
| | | Média | 0.0651 | 0.3954 | 0.4058 | 1.3841 |
| | | Melhor | 2.6498e-06 | 0.0072 | 0.0052 | 0.0010 |
| | $\mu = 30\%$ | Pior | 0.6126 | 1.0042 | 0.6878 | 11.7182 |
| | | Média | 0.0641 | 0.2682 | 0.1728 | 1.2063 |
| | | Melhor | 3.1095e-10 | 0.0213 | 1.4582e-04 | 3.8183e-4 |

Fonte: Elaborado pelo autor

Analisando o caso médio temos o fato de o algoritmo proposto neste trabalho apresentar resultados satisfatórios em todas as funções ao compararmos o mesmo fator com o AG Padrão, com destaque para o AGSS com probabilidade de seleção de 30% na função Schwefel que reduziu a média de 0.5105 encontrado no AG padrão para 0.0641 encontrado no algoritmo proposto neste trabalho.

Diante de todos os testes realizados e apresentados neste trabalho podemos perceber que o algoritmo proposto neste trabalho, o Algoritmo Genético com Seleção Sexual- AGSS, apresenta-se como uma variância considerável ao AG Padrão. Apresentando melhores resultados em desvio padrão, média, pior e melhor caso o algoritmo proposto neste trabalho pode contribuir para pesquisa com algoritmos meta-heurísticos em resolução de problemas de otimização.

7. CONSIDERAÇÕES FINAIS

Este trabalho apresenta o novo Algoritmo Genético e Seleção Sexual (AGSS), com uma estrutura básica para uma nova forma de implementação do Algoritmo Genético padrão. Introduzimos a ideia de seleção sexual através do nível de atração de uma fêmea para os machos selecionados da população.

O AGSS é um modelo genérico de algoritmo que pode ser modificado a partir das necessidades que o problema exigir, por exemplo, a taxa de seleção sexual, que neste trabalho está definida para fim de testes iniciais em 10%, 20% e 30%, pode ser alterada a fim de encontrar uma taxa que mais se adeque a determinados problemas. Outro exemplo pode ser a auto adaptação da taxa de seleção sexual.

Com a inserção da seleção sexual no algoritmo genético base, comprovaram-se por meio de testes de validação, melhorias significativas no algoritmo genético base, tanto na média das soluções encontradas a cada execução quanto no desvio padrão calculado ao fim de 50 execuções. Ficando para estudos futuros, projeto auto adaptativo da taxa de seleção sexual que pode variar assim influenciando na pressão seletiva do ambiente. O método de seleção determinística para a fêmea e para os machos segue como sugestão já que neste trabalho são escolhidos de forma aleatória.

REFERÊNCIAS

Goldberg, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Reading Massachusetts, Addison-Wesley (1989).

Darwin, C. **On the origin of species**, 1st Ed. London: John Murray(1859).

Cronin, H. **The ant and the peacock: Altruism and sexual selection from Darwin to today**. Cambridge: Cambridge Univ. Press (1991).

Darwin, C. **The descent of man, and selection in relation to sex**. London: John Murray (1871).

Catchpole, C. K. **Sexual selection and the evolution of complex songs among European warblers of the genus Acrocephalus**. Behaviour, 74, 149–166 (1980).

Todd, P. M; Miller, G. F. **Parental guidance suggested: How parental imprinting evolves through sexual selection as an adaptive learning mechanism.** *Adaptive Behavior*, 2 (1993).

Eldredge, N. **Unfinished synthesis: Biological hierarchies and modern evolutionary thought.** New York: Oxford U. Press (1985).

Eldredge, N. **Information, economics, and evolution.** *Ann. Review of Ecology and Systematics*, 17, 351-369(1986).

Eldredge, N. **Macroevolutionary dynamics: Species, niches, and adaptive peaks.** New York: McGraw-Hill (1989)

Fisher, R. A. **The genetical theory of natural selection.** Oxford: Clarendon Press (1930).

Jamil, M; Yang, X. **A literature survey of benchmark functions for global optimization problems,** *Int. Journal of Mathematical Modelling and Numerical Optimisation*, Vol. 4, No. 2, pp. 150–194 (2013).