Computação Bioinspirada

Aula 05

azevedolab.net

No algoritmo genético, a geração aleatória de indivíduos de uma dada população é uma etapa de importância fundamental. Esse processo é chamado de inicialização na figura abaixo. Com a biblioteca *NumPy*, temos a possibilidade de fixarmos uma semente aleatória, para garantir que os números aleatórios iniciais sejam mantidos, para uma dada semente aleatória.

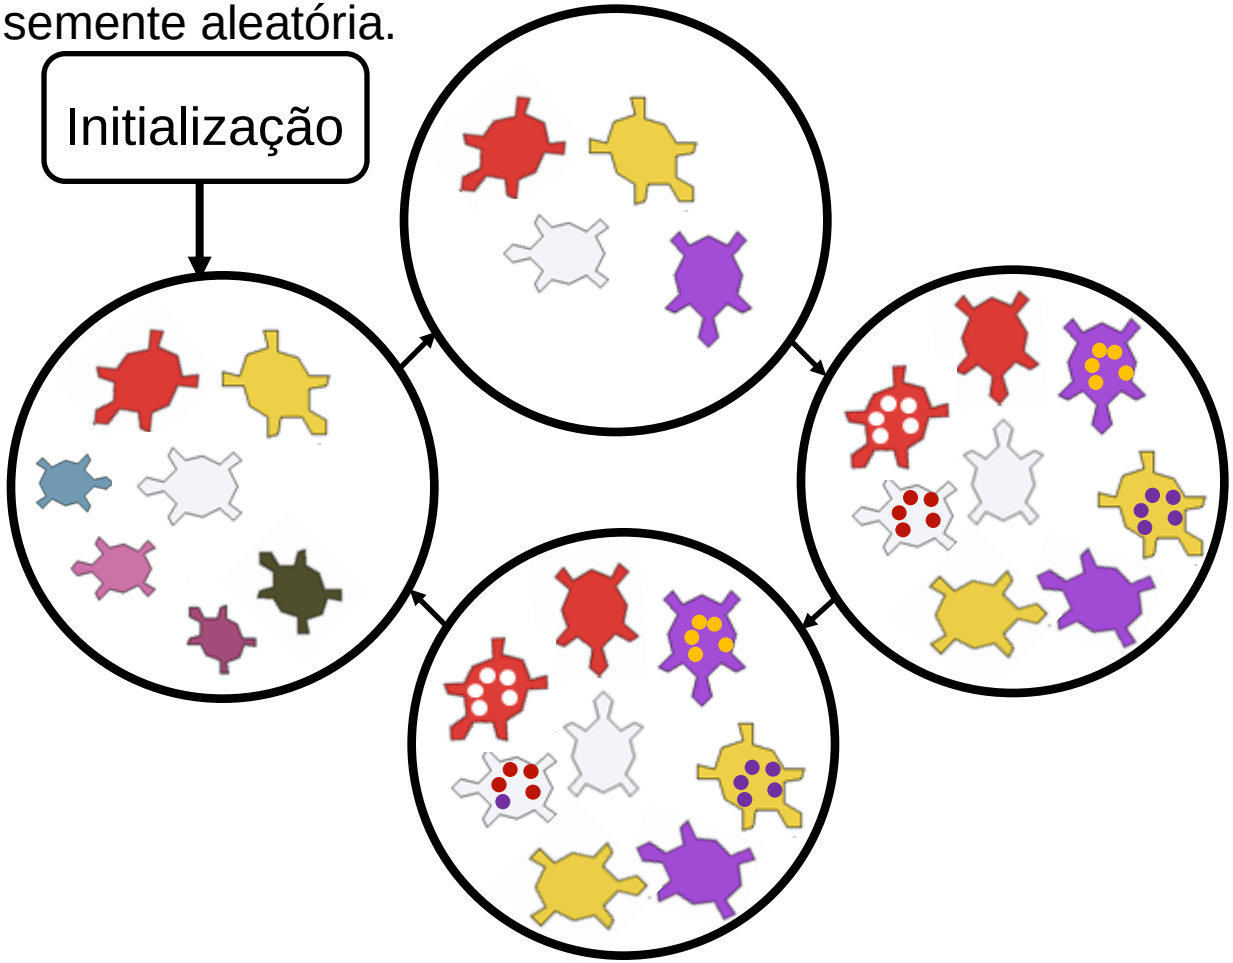

Para definição da semente aleatória, usamos o comando abaixo. No exemplo abaixo, a semente aleatória é um número inteiro atribuído à variável *seed_in.*

```
np.random.seed(seed_in)
```

A linha acima deve ser inserida antes da geração do número aleatório. Por exemplo, o código abaixo (*random_with_seed.py*) gera um número aleatório entre 0 e 9.

```
# Import library
import numpy as np
# Set up seed
np.random.seed(31415)
# Generate random number
rs = np.random.randint(0,9)
print(rs)
```

Veja que a definição da semente aleatório aparece antes da definição do número aleatório, que ocorre na linha *rs = np.random.randint(0,9).*

O código *random_loop.py* repete a geração de número aleatório dentro de um loop *for*, como mostrado abaixo.

```
# Import library
import numpy as np
# Loop for generation of random numbers
for i in range(10):
        # Set up seed
        np.random.seed(31415)
        # Generate random number
        rs = np.random.randint(0,9)
print(rs)
```

Abaixo temos o resultado obtido com o programa *random_loop.py.* Anterior a geração do número aleatório em cada iteração, temos a fixação da semente aleatória. O resultado é que temos sempre o mesmo número gerado.

```
7
7
7
7
7
7
7
7
7
7
```

Colocando-se a linha da semente aleatória como comentário no código *random_loop.py,* os números passam a variar.

```
# Import library
import numpy as np
# Loop for generation of random numbers
for i in range(10):
        # Set up seed
        # np.random.seed(31415)
        # Generate random number
        rs = np.random.randint(0,9)
print(rs)
```

Como não temos semente aleatória, o código gera números distintos, como podemos ver no resultado abaixo.

```
0
1
3
2
3
3
1
6
8
4
```

Abaixo temos o código do novo método para gerar strings binárias com semente. A principal novidade é que temos um atributo do objeto para a semente, atribuído à variável *self.seed_in*. Essa variável é usada na linha *np.random.seed(self.seed_in).*

```
def gen_bin_string_seed(self):
        """Method to generate binary strings"""
        # Import library
        import numpy as np
        # Set up seed for random number
        np.random.seed(self.seed_in)
        # Set up arrays of zeros
        self.max_array = np.zeros(self.max_iter)
        self.mean_array = np.zeros(self.max_iter)
        # Set up empty list
        bin_str_list = []
        # Generate binary string
        for i in range(self.pop_size):
            bin1 = np.random.randint(2,size=self.len_str)     # Binary (2) strings
            bin_str0 = str(bin1)
            bin_str0 = bin_str0.replace(" ","")
            bin_str0 = bin_str0.replace("[","")
            bin_str0 = bin_str0.replace("]","")
            bin_str_list.append(bin_str0)
        # Update population
        self.current_pop = bin_str_list
        print("\nInitial Population")
        # Looping through initial population
        for bin_string in self.current_pop:
            print(bin_string)
```

Uma vez estabelecida a semente, os números aleatórios serão mantidos. No final do método temos um loop *for* para exibir a população inicial. O método construtor foi modificado, de forma a acomodar o atributo *self.seed_in*.

```
def gen_bin_string_seed(self):
        """Method to generate binary strings"""
        # Import library
        import numpy as np
        # Set up seed for random number
        np.random.seed(self.seed_in)
        # Set up arrays of zeros
        self.max_array = np.zeros(self.max_iter)
        self.mean_array = np.zeros(self.max_iter)
        # Set up empty list
        bin_str_list = []
        # Generate binary string
        for i in range(self.pop_size):
            bin1 = np.random.randint(2,size=self.len_str)     # Binary (2) strings
            bin_str0 = str(bin1)
            bin_str0 = bin_str0.replace(" ","")
            bin_str0 = bin_str0.replace("[","")
            bin_str0 = bin_str0.replace("]","")
            bin_str_list.append(bin_str0)
        # Update population
        self.current_pop = bin_str_list
        print("\nInitial Population")
        # Looping through initial population
        for bin_string in self.current_pop:
            print(bin_string)
```

Abaixo temos o trecho inicial da definição da classe com destaque para o método construtor. Vemos em vermelho o texto que foi adicionado à classe *Simple_GA02*() para a semente aleatória. Também foram adicionados atributos para os valores mínimo e máximo da faixa de *float* (*self.f_min* e *self.f_max*). Outro atributo adicionado refere-se ao fator de conversão para o tamanho das tartarugas. Esses atributos serão discutidos nos próximos slides.

```
class Simple_GA02(object):
    """A class to implement a simple GA"""

    # Constructor method
    def __init__(self,pop_size,max_iter,p_cross,len_str,p_mut,f_min,f_max,conv_f,seed_in):

        # Define atributes
        self.pop_size = pop_size            # Population size
        self.max_iter = max_iter            # Number of iterations
        self.p_cross = p_cross              # Probability of crossover
        self.len_str = len_str              # String length
        self.p_mut = p_mut                  # Probability of mutation_Coley_algo_03
        self.f_min = f_min                  # Minimum float
        self.f_max = f_max                  # Maximum float
        self.conv_f = conv_f                # Conversion factor
        self.seed_in = seed_in              # Seed for generation of random numbers
```

Nas últimas aulas implementamos o algoritmo 1 de Colley 1999 que acha o máximo da função x^2 entre os inteiros 0 e 4095. Muitos problemas de otimização não se restringe-se ao conjunto dos inteiros. Para apresentarmos a solução do problema de maximização, vamos considerar que a faixa de números está entre 1,25 e 3,14. Os novos números são chamados de *floats* mínimo e máximo e são representados pelas variáveis f_{min} e f_{max}.

String binária	Integers	Floats
0 0 0 0 0 0 0 0 0 0 0 0	0	1.25
0 0 0 0 0 0 0 0 0 0 0 1	1	
0 0 0 0 0 0 0 0 0 0 1 0	2	
0 0 0 0 0 0 0 0 0 0 1 1	3	
0 0 0 0 0 0 0 0 0 1 0 0	4	
0 0 0 0 0 0 0 0 0 1 0 1	5	
0 0 0 0 0 0 0 0 0 1 1 0	6	
0 0 0 0 0 0 0 0 0 1 1 1	7	
0 0 0 0 0 0 0 0 1 0 0 0	8	
.....	.....	
1 1 1 1 1 1 1 1 1 1 1 0	4094	
1 1 1 1 1 1 1 1 1 1 1 1	4095	3.14

De uma forma geral, podemos dizer que para cada inteiro temos um equivalente *float,* colocando em forma matemática temos:

$$f_{\min} = \alpha_0 + \alpha_1 i_{\min}$$

$$f_{\max} = \alpha_0 + \alpha_1 i_{\max}$$

Onde os *f's* representam os *floats* e os *i's* representam os inteiros. As constantes α's são usadas para convertermos de inteiro para *float.* Considerando-se que i_{min} = 0 temos:

$$f_{\min} = \alpha_0$$

Calculando-se $f_{max} - f_{min}$ chegamos:

$$f_{\max} - f_{\min} = \alpha_0 + \alpha_1 i_{\max} - \alpha_0$$

$$f_{\max} - f_{\min} = \alpha_1 i_{\max} \Rightarrow \boxed{\alpha_1 = \frac{f_{\max} - f_{\min}}{i_{\max}}}$$

Assim, o *float* equivalente (*f)* a um inteiro qualquer *i* é dado por:

$$f = \alpha_0 + \alpha_1 i = f_{\min} + \alpha_1 i = f_{\min} + \left(\frac{f_{\max} - f_{\min}}{i_{\max}} \right) i$$

Agora temos uma equação geral onde podemos obter qualquer *float,* a partir do conhecimento da faixa de inteiros que dispomos e da definição da faixa de *floats* que queremos analisar.

$$f = f_{\min} + \left(\frac{f_{\max} - f_{\min}}{i_{\max}} \right) i$$

Considerando-se uma string binária de *l* bits, o número inteiro máximo que pode ser representado é dado por:

$$i_{\max} = 2^l - 1$$

Assim, substituindo-se esse valor na equação do *float,* temos:

$$f = f_{\min} + \left(\frac{f_{\max} - f_{\min}}{2^l - 1} \right) i$$

Um aspecto importante na aplicação de algoritmos genéticos é a acurácia. Por exemplo, quando consideramos a equivalência entre a faixa de 0 a 4095 com a faixa de 1,25 a 3,14. Vemos que entre dois números consecutivos em decimal, por exemplo, 1000 e 1001, temos os equivalentes em *float:*

$$f = 1{,}25 + \left(\frac{3{,}14 - 1{,}25}{4095} \right) 1000 = 1{,}71153846$$

$$f = 1{,}25 + \left(\frac{3{,}14 - 1{,}25}{4095} \right) 1001 = 1{,}71200000$$

Assim, entre 1,7115 e 1,7120 não temos representação *float.* Ou seja, temos aproximadamente 0,0005 de acurácia. Uma forma de aumentarmos a acurácia, é aumentando-se o tamanho das strings binárias. Uma forma de calcularmos a acurácia é dividirmos a faixa de *floats* ($f_{max} - f_{min}$) pela quantidade de inteiros (i_{max}).

No novo código, criamos um método para implementar a equação de conversão de inteiro para *float*. O novo método é chamado *int2float().* O código está destacado abaixo. Os parâmetros do método trazem o *float* mínimo (*f_min*), o *float* máximo (*f_max*) e o inteiro a ser convertido *(i*). Esses valores são usados para o cálculo do *f* que retorna para onde o método foi invocado, dentro do método *coley_algo_03().*

```
def int2float(self,i):
        """Method to convert integer to float"""

        f = self.f_min + i*(self.f_max - self.f_min)/(2**(self.len_str) -1)

        return f
```

Outra modificação foi na função *show_pop()*, que passa a mostrar os valores *floats* para o indivíduo e a função ajuste, além da string binária.

```
def show_pop(self,string2show,pop2show,f_in,function_in):
        """Method to show population"""

        # Show information concerning the population
        print("\n"+string2show)

        # Looping though the elements of the population
        for i in range(len(pop2show)):
            print(pop2show[i],"  %.3f"%f_in[i],"  %.3f"%function_in[i])
```

O operador seleção que usamos até o momento é relativamente simples de implementar, mas não é o mais comum no estudo de algoritmos genéticos. Uma abordagem mais robusta do operador seleção leva em conta o valor da função ajuste na seleção, mas não necessariamente elimina indivíduos com os valores mais baixos. Esta abordagem é chamada roleta de cassino.

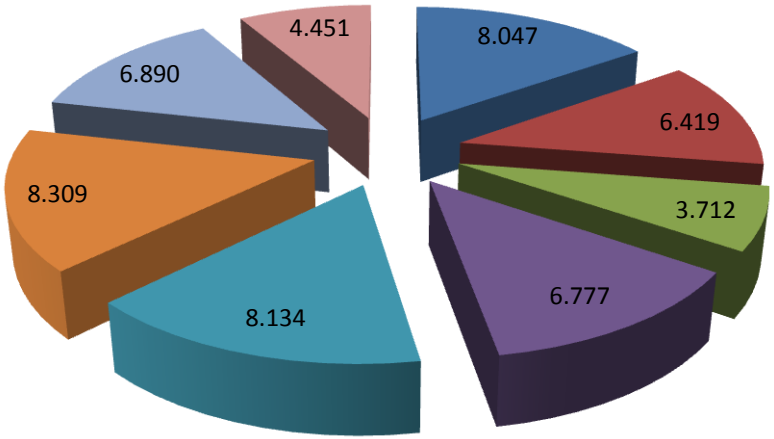

A abordagem de roleta de cassino soma todos os valores da função ajuste e atribui à variável fit_{sum}. Então é gerado um número aleatório (r_s) entre zero e fit_{sum} . Em seguida um loop vai somando os valores da função ajuste de cada indivíduo da população, esses valores são somados à variável $fit_{partial}$. Quando a condição $fit_{partial}$.> r_s for satisfeita, o loop é encerrado e o último indivíduo somado é considerado selecionado para a próxima geração. Esse processo se repete até que a população atinja o número de indivíduos estabelecido para a população.

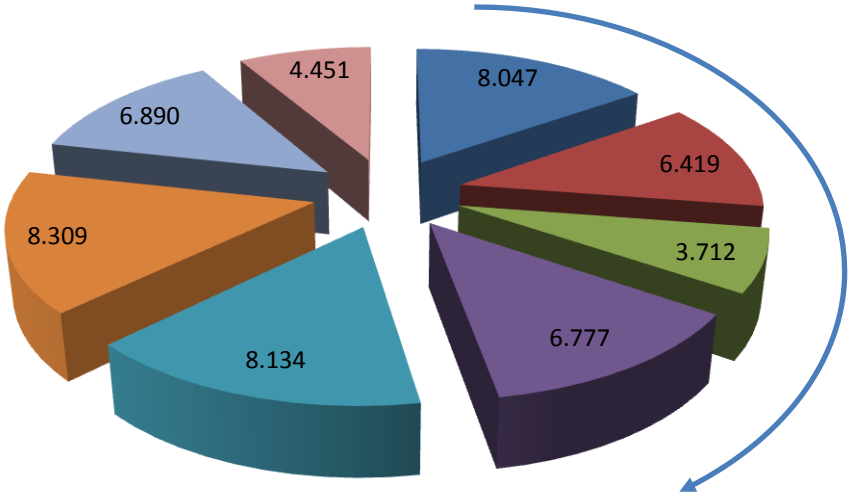

r_s = 23,546

$fit_{partial}$ = 24,955

Para ilustrar uma iteração do operador seleção com roleta de cassino, considere os valores da função ajuste mostrados no gráfico abaixo. Foi gerado um número aleatório entre zero e soma de todos os valores da função ajuste (52,739), por exemplo, r_s = 23,546. Em seguida somamos os valores de cada função ajuste e testamos a condição $fit_{partial}$.> r_s , quando for satisfeita paramos a soma. O indivíduo que gerou o último valor da função ajuste (6,777) é selecionado.

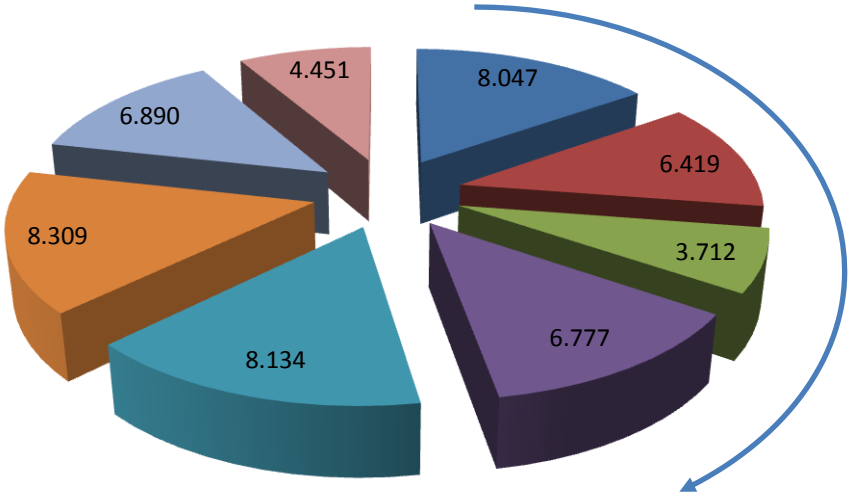

r_s = 23,546

$fit_{partial}$ = 24,955

Abaixo temos o fluxograma do algoritmo 2 de Coley 1999, que implementa a roleta de cassino para seleção de indivíduos.

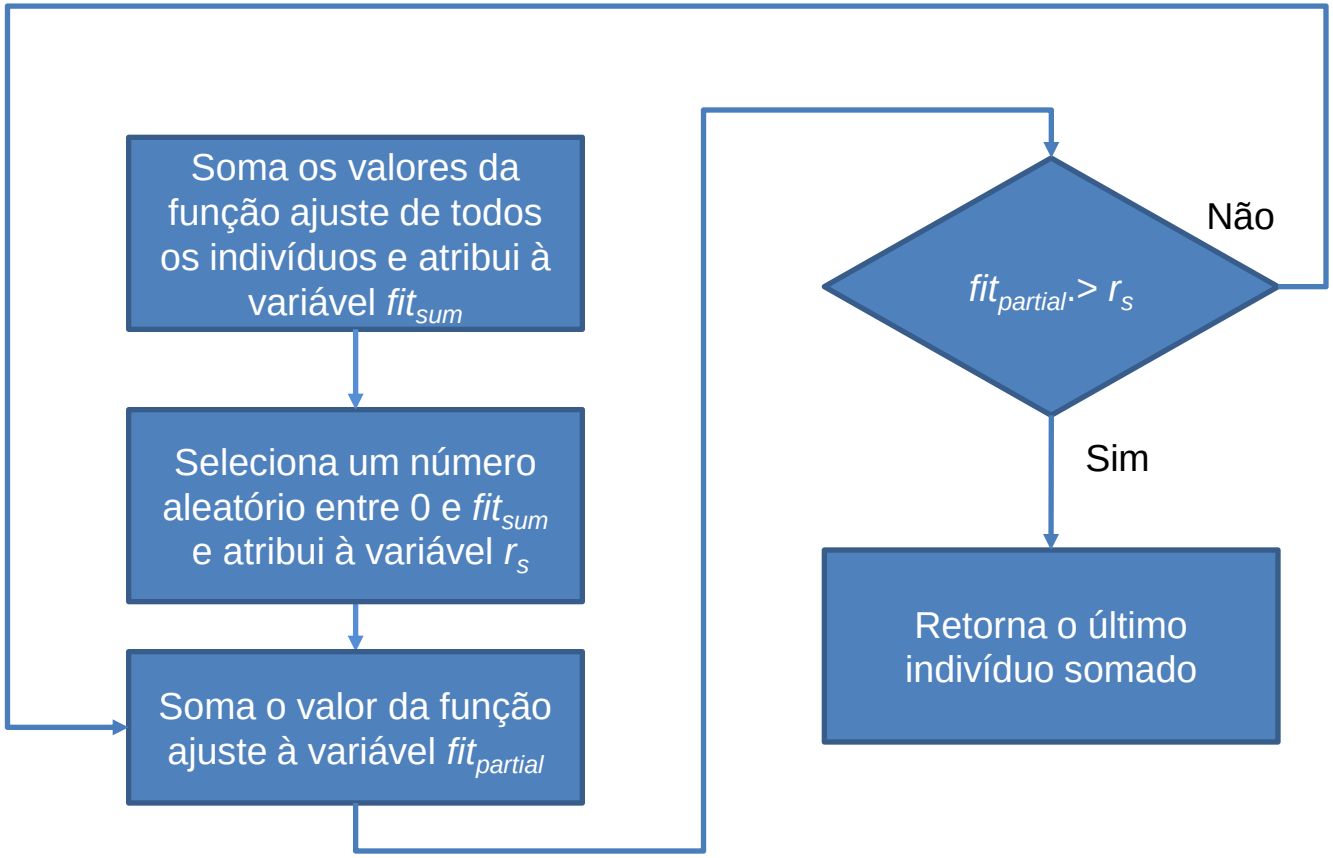

Abaixo temos o método *roulette_wheel()*. Inicialmente somamos os valores da função ajuste de todos os indivíduos e atribuímos à variável *fit_sum.*

```
def roulette_wheel(self):
        """Method for application of roulette wheel to a population"""
        # Import library
        import numpy as np
        # Sum fitness function vaules
        fit_sum = np.sum(self.fit)
        # Set up empty list
        new_pop = []
        # Looping through all individuals
        for j in range(self.pop_size):
            # Generate random number
            rs =np.random.uniform(0,fit_sum)
            # Set up initial value for fit_partial
            fit_partial = 0
            # Looping through inidividual until fit_partial > rs
            for i in range(self.pop_size):
                fit_partial += self.fit[i]
                # Check if condition is satisfied
                if fit_partial > rs:
                    new_pop.append(self.current_pop[i])
                    break
        # Update population
        self.current_pop = new_pop
```

Agora dentro de um loop *for*, geramos uma número aleatório entre zero e a soma dos valores da função ajuste e atribuímos à variável *rs.*

```
def roulette_wheel(self):
        """Method for application of roulette wheel to a population"""
        # Import library
        import numpy as np
        # Sum fitness function vaules
        fit_sum = np.sum(self.fit)
        # Set up empty list
        new_pop = []
        # Looping through all individuals
        for j in range(self.pop_size):
            # Generate random number
            rs =np.random.uniform(0,fit_sum)
            # Set up initial value for fit_partial
            fit_partial = 0
            # Looping through inidividual until fit_partial > rs
            for i in range(self.pop_size):
                fit_partial += self.fit[i]
                # Check if condition is satisfied
                if fit_partial > rs:
                    new_pop.append(self.current_pop[i])
                    break
        # Update population
        self.current_pop = new_pop
```

Esse primeiro loop *for* varre toda população. Interno ao primeiro loop, temos um segundo loop *for* para realizarmos a função da roleta de cassino.

```
def roulette_wheel(self):
        """Method for application of roulette wheel to a population"""
        # Import library
        import numpy as np
        # Sum fitness function vaules
        fit_sum = np.sum(self.fit)
        # Set up empty list
        new_pop = []
        # Looping through all individuals
        for j in range(self.pop_size):
            # Generate random number
            rs =np.random.uniform(0,fit_sum)
            # Set up initial value for fit_partial
            fit_partial = 0
            # Looping through inidividual until fit_partial > rs
            for i in range(self.pop_size):
                fit_partial += self.fit[i]
                # Check if condition is satisfied
                if fit_partial > rs:
                    new_pop.append(self.current_pop[i])
                    break
        # Update population
        self.current_pop = new_pop
```

No segundo loop vamos somando os valores da função ajuste até que este ultrapasse o número aleatório *rs*. Ao passar, adicionamos o último elemento à nova população.

```
def roulette_wheel(self):
        """Method for application of roulette wheel to a population"""
        # Import library
        import numpy as np
        # Sum fitness function vaules
        fit_sum = np.sum(self.fit)
        # Set up empty list
        new_pop = []
        # Looping through all individuals
        for j in range(self.pop_size):
            # Generate random number
            rs =np.random.uniform(0,fit_sum)
            # Set up initial value for fit_partial
            fit_partial = 0
            # Looping through inidividual until fit_partial > rs
            for i in range(self.pop_size):
                fit_partial += self.fit[i]
                # Check if condition is satisfied
                if fit_partial > rs:
                    new_pop.append(self.current_pop[i])
                    break
        # Update population
        self.current_pop = new_pop
```

O processo é repetido até que a nova população, atribuída à variável *new_pop*, volte a ter o número original de indivíduos. Por último, a população é atualizada.

```
def roulette_wheel(self):
        """Method for application of roulette wheel to a population"""
        # Import library
        import numpy as np
        # Sum fitness function vaules
        fit_sum = np.sum(self.fit)
        # Set up empty list
        new_pop = []
        # Looping through all individuals
        for j in range(self.pop_size):
            # Generate random number
            rs =np.random.uniform(0,fit_sum)
            # Set up initial value for fit_partial
            fit_partial = 0
            # Looping through inidividual until fit_partial > rs
            for i in range(self.pop_size):
                fit_partial += self.fit[i]
                # Check if condition is satisfied
                if fit_partial > rs:
                    new_pop.append(self.current_pop[i])
                    break
        # Update population
        self.current_pop = new_pop
```

O uso da roleta no operador seleção pode levar a perda do melhor indivíduo de uma dada geração. Assim, é comum usarmos a opção de elitismo no algoritmo genético. Com elitismo o melhor indivíduo do operador seleção é salvo e mantido para próxima geração. Abaixo temos o método *elitism()*. Nesse método identificamos o maior valor da função ajuste na linha *max_fit = np.max(my_array)*.

```
def elitism(self):
        """Method for elitism"""
        # Import libraries
        import numpy as np
        import test_function as tf
        # Call bin2dec_array()
        dec = self.bin2dec_array(self.current_pop)
        # Call int2float()
        my_float = self.int2float(dec)
        # Instantiating an object of the Function() class and assigns it to the variable fit0
        fit0 = tf.Function(my_float)
        # Invoking the fitness_funct() method
        my_fit = fit0.fitness_func()
        # Set up an array
        my_array = np.array(my_fit)
        # Find the maximum for the fitness function and assigns it to max_fit
        max_fit = np.max(my_array)
        # Set up an empty list
        new_pop = []
        # Find the position for the max_fit in the my_array
        pos_array = np.where( my_array == max_fit)
        # Get the integer for index
        my_index = int(pos_array[0][0])
        # Assign elite member to self.elite
        self.elite = self.current_pop[my_index]
        # Show elite member
        print("Elite member: ", self.elite, max_fit
```

O valor atribuído à variável *max_fit* é usado para identificar o índice do elemento do array que tem o máximo. Isso é feito em *pos_array = np.where(my_array == max_fit).* Como podemos ter mais de um índice com o máximo, é atribuído à variável *pos_array* um array, onde nos interessa só uma das posições. Na linha *my_index = int(pos_array[0][0])* atribuímos o índice do elemento máximo à variável *my_index.*

```
def elitism(self):
        """Method for elitism"""
        # Import libraries
        import numpy as np
        import test_function as tf
        # Call bin2dec_array()
        dec = self.bin2dec_array(self.current_pop)
        # Call int2float()
        my_float = self.int2float(dec)
        # Instantiating an object of the Function() class and assigns it to the variable fit0
        fit0 = tf.Function(my_float)
        # Invoking the fitness_funct() method
        my_fit = fit0.fitness_func()
        # Set up an array
        my_array = np.array(my_fit)
        # Find the maximum for the fitness function and assigns it to max_fit
        max_fit = np.max(my_array)
        # Set up an empty list
        new_pop = []
        # Find the position for the max_fit in the my_array
        pos_array = np.where( my_array == max_fit)
        # Get the integer for index
        my_index = int(pos_array[0][0])
        # Assign elite member to self.elite
        self.elite = self.current_pop[my_index]
        # Show elite member
        print("Elite member: ", self.elite, max_fit
```

Agora obtemos elemento elite com a linha *self.elite = self.current_pop[my_index].* Essa variável será usada no método *include_elite.*

```
def elitism(self):
        """Method for elitism"""
        # Import libraries
        import numpy as np
        import test_function as tf
        # Call bin2dec_array()
        dec = self.bin2dec_array(self.current_pop)
        # Call int2float()
        my_float = self.int2float(dec)
        # Instantiating an object of the Function() class and assigns it to the variable fit0
        fit0 = tf.Function(my_float)
        # Invoking the fitness_funct() method
        my_fit = fit0.fitness_func()
        # Set up an array
        my_array = np.array(my_fit)
        # Find the maximum for the fitness function and assigns it to max_fit
        max_fit = np.max(my_array)
        # Set up an empty list
        new_pop = []
        # Find the position for the max_fit in the my_array
        pos_array = np.where( my_array == max_fit)
        # Get the integer for index
        my_index = int(pos_array[0][0])
        # Assign elite member to self.elite
        self.elite = self.current_pop[my_index]
        # Show elite member
        print("Elite member: ", self.elite, max_fit
```

O método *include_elite()* usa o elemento *self.elite* para substituir um elemento aleatório da população. Assim garantimos que o elemento elite está na população ao final da geração. O método *include_elite()* será evocado logo após a evocação do método do operador mutação.

```
def include_elite(self):
        """Method to include elite member in the current population"""
        # Import library
        import numpy as np
        # Generate random number
        rs = np.random.randint(0,self.pop_size)

        # Set up empty list
        new_pop = []

        # Looping through population and change for elite meber at random position
        for i in range(self.pop_size):
            if i != rs:
                new_pop.append(self.current_pop[i])
            else:
                new_pop.append(self.elite)
        # Update current_pop
        self.current_pop = new_pop
```

Nesse método geramos um número aleatório entre zero e o tamanho da população e atribuímos à variável *rs.* Em seguida criamos uma lista vazia que é atribuída à variável *new_pop.* Na sequência, temos um loop *for* que varre a população e testa se o índice do elemento da população é diferente do número interior aleatório. Se for mantém o elemento, caso contrário o elemento é substituído pelo elemento elite. Por último, a população é atualizada, garantindo-se a presença do elemento elite.

```
def include_elite(self):
        """Method to include elite member in the current population"""
        # Import library
        import numpy as np
        # Generate random number
        rs = np.random.randint(0,self.pop_size)

        # Set up empty list
        new_pop = []

        # Looping through population and change for elite meber at random position
        for i in range(self.pop_size):
            if i != rs:
                new_pop.append(self.current_pop[i])
            else:
                new_pop.append(self.elite)
        # Update current_pop
        self.current_pop = new_pop
```

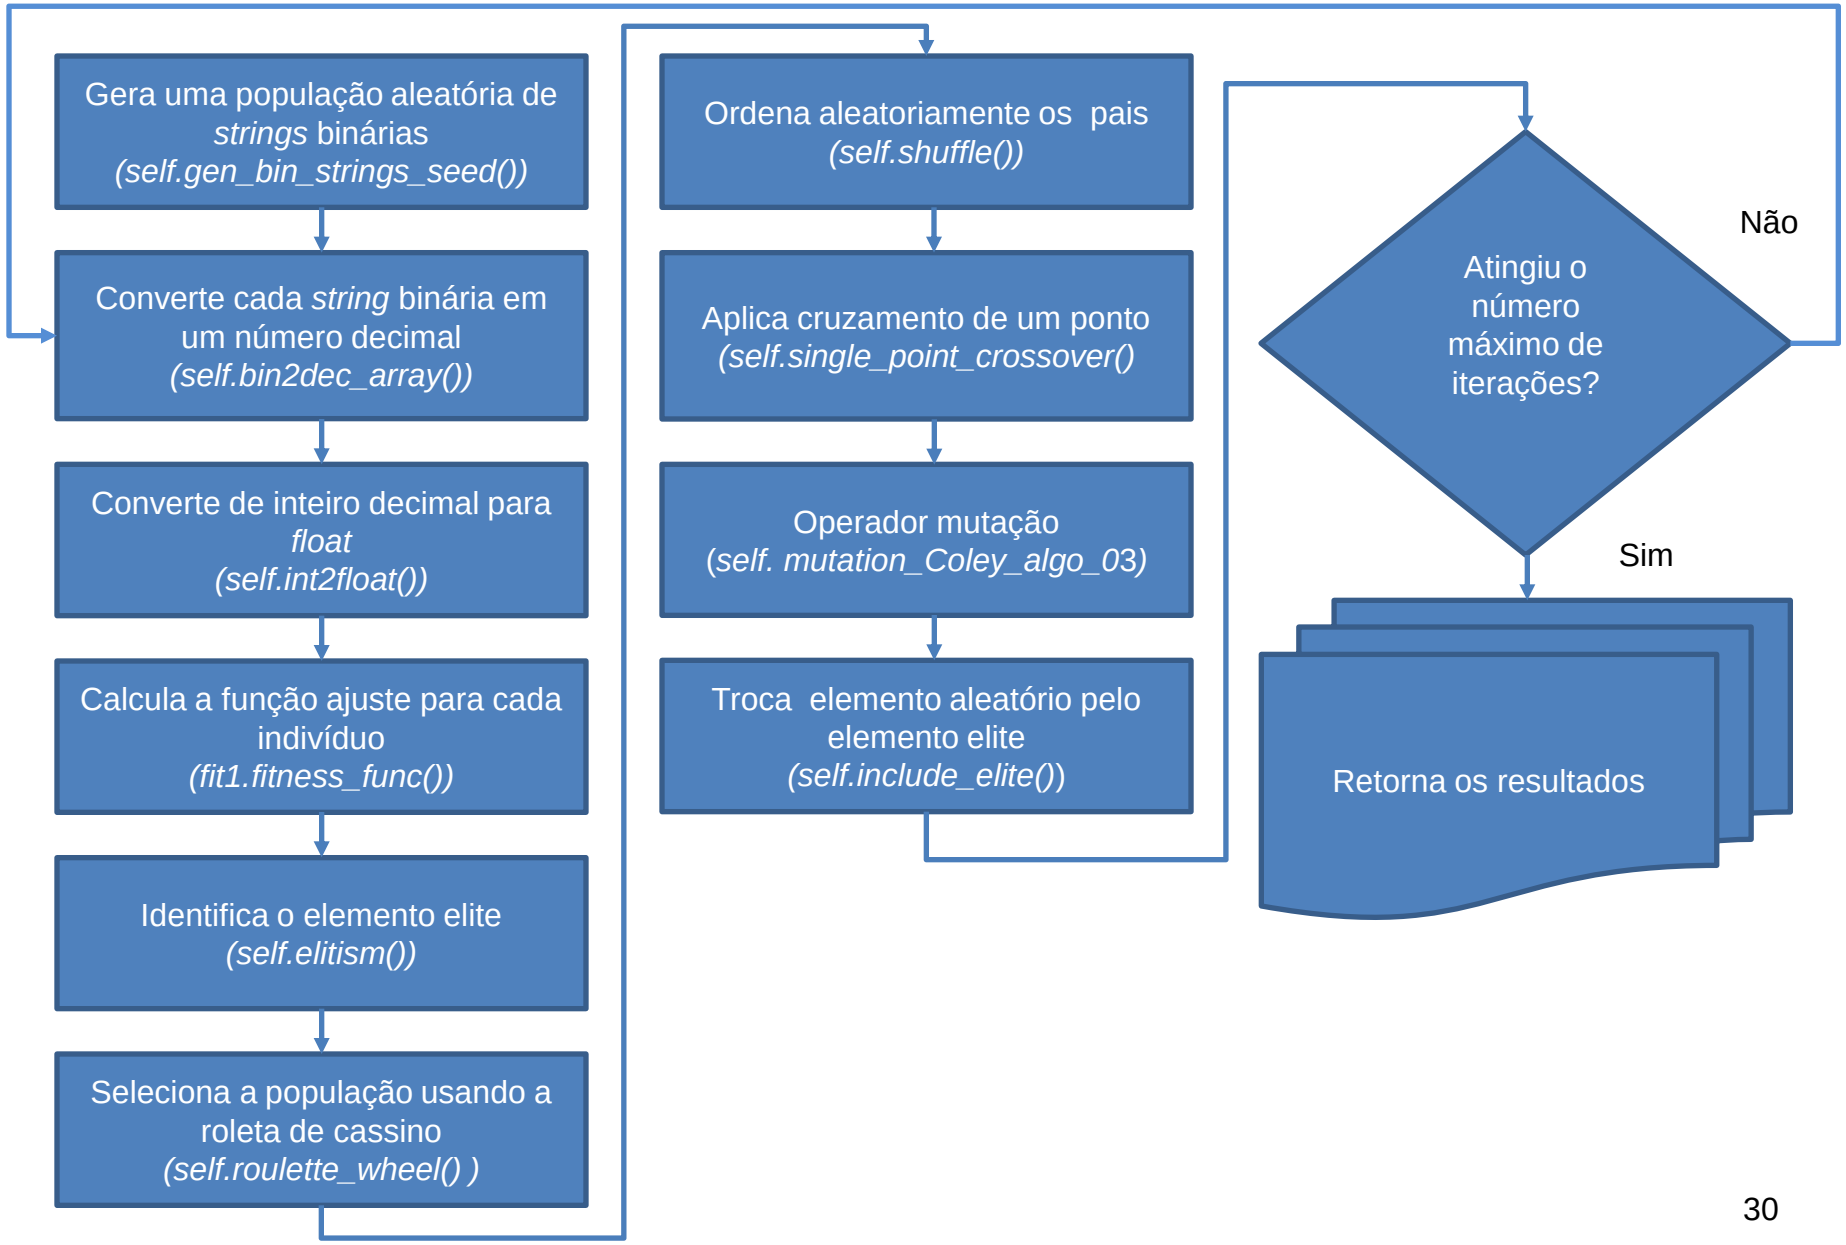
Gera uma população aleatória de *strings* binárias *(self.gen_bin_strings_seed())*
Converte cada *string* binária em um número decimal *(self.bin2dec_array())*
Converte de inteiro decimal para *float* *(self.int2float())*
Calcula a função ajuste para cada indivíduo *(fit1.fitness_func())*
Identifica o elemento elite *(self.elitism())*
Seleciona a população usando a roleta de cassino *(self.roulette_wheel())*
Ordena aleatoriamente os pais *(self.shuffle())*
Aplica cruzamento de um ponto *(self.single_point_crossover()*
Operador mutação *(self. mutation_Coley_algo_03)*
Troca elemento aleatório pelo elemento elite *(self.include_elite())*
Atingiu o número máximo de iterações?
Não
Sim
Retorna os resultados

Até agora implementamos um algoritmo genético para achar o máximo da função f(x) = x^2, uma função relativamente simples. Normalmente as funções para os quais estamos interessados em achar o mínimo ou o máximo são mais complexas. A fim de padronizar testes de eficiência de algoritmos de otimização, são usadas funções matemáticas que apresentam maiores variações. Há diversas funções que são consideradas padrões para testes, principalmente para funções de mais de uma variável. Iremos aqui parte nos restringir a funções de uma variável.

Para facilitar a codificação, criamos uma classe a parte do código *lga01.py* onde está implementada a função ajuste. Abaixo temos o código *test_function.py.* A linha em vermelho traz a codificação da função f(x) = x^2, que é a nossa função teste. Resumindo, usamos como função ajuste uma função teste, como objetivo de avaliar o desempenho do algoritmo.

```
class Function(object):
    """Class to calculate an one-variable mathematical function"""
    def __init__(self,x):
        self.x = x
    # Definition of fitness_func()
    def fitness_func(self):
        """Method to calculate fitness function"""
        import numpy as np

        f = self.x**2        # [1.25,3.14]    conv_factor = 0.45      max = 3.14
        return f
```

Abaixo temos o gráfico de algumas funções que podem ser implementadas em *test_function.py*.

$$f(x) = x^2$$

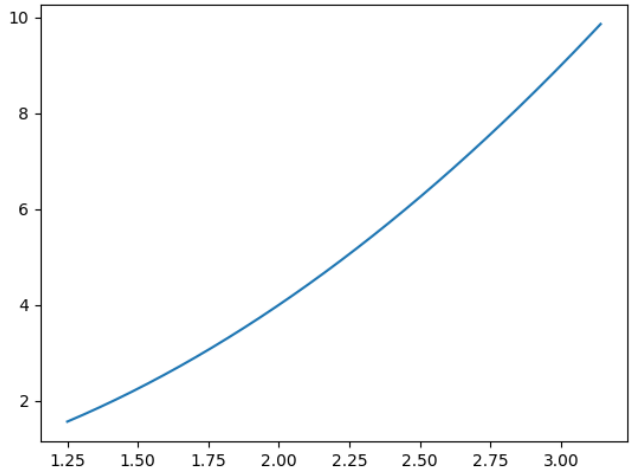

$$f(x) = 6x - x^2$$

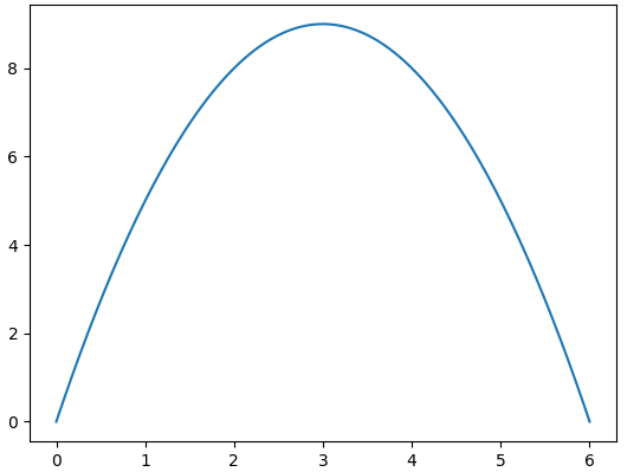

$$f(x) = 7x - x^2 - 12$$

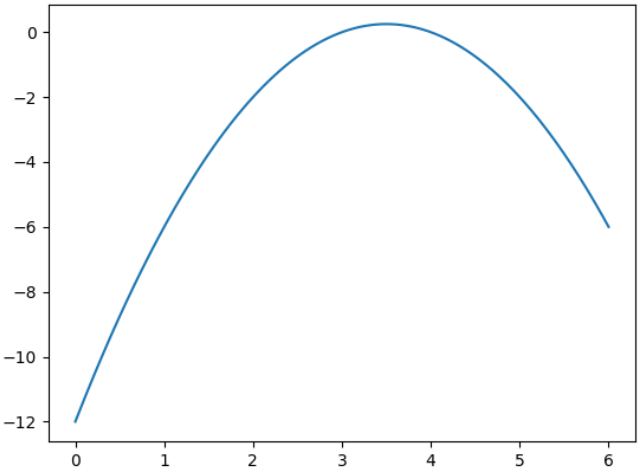

$$f(x) = x^2.\sin(x)$$

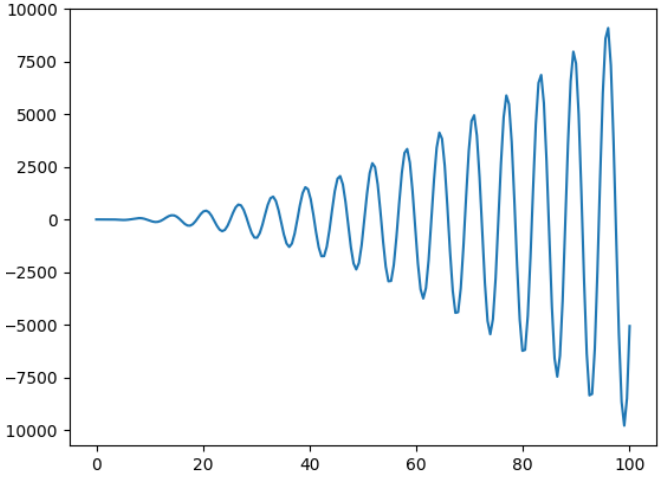

Usamos os seguintes parâmetros para o programa *lga01.py*.

pop_size = 8 # Population size
max_iter = 25 # Number of iterations
p_cross = 0.8 # Probability of crossover
len_str = 12 # Length of strings
p_mut = 0.01 # Probability of mutation_Coley_algo_03
seed = 314159 # Seed for generation of random number
min_f = 0.0 # Minimum float
max_f = 100.0 # Maximum float
conv_factor = 0.0005 # Conversion factor (fitness function to dimensions)

Foi usada a seguinte função teste, $f(x) = x^2.\sin(x)$, com intervalo entre 0 e 100.

Abaixo temos os resultados obtidos com os parâmetros do slide anterior para o programa *lga01.py.*

```
Population for generation 25
111101110101    96.630    6428.212
111011101011    93.260    -7260.322
110111010111    86.520    -7426.064
101110101111    73.040    -3765.778
011101011111    46.081    1834.788
111101110101    96.630    6428.212
110101111101    84.322    3412.940
101011111011    68.645    -2135.512
```

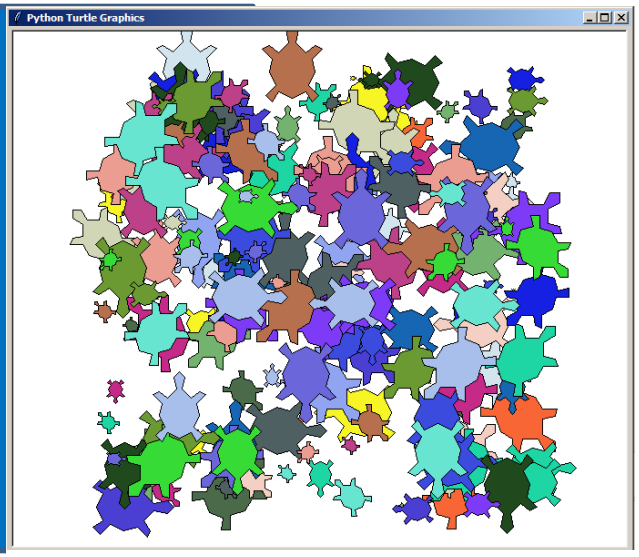

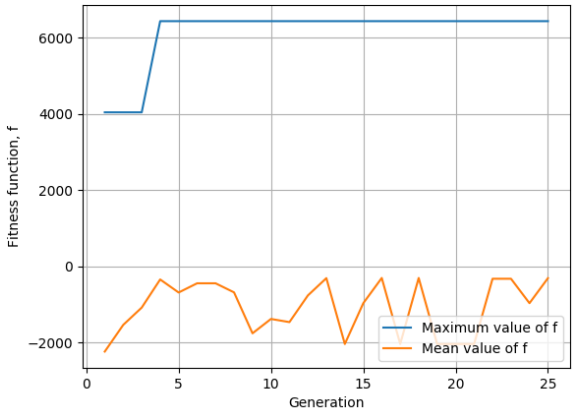

O melhor resultado é obtido para x = 96.630, que é o máximo indicado na função abaixo.

```
Population for generation 25
111101110101    96.630    6428.212
111011101011    93.260    -7260.322
110111010111    86.520    -7426.064
101110101111    73.040    -3765.778
011101011111    46.081    1834.788
111101110101    96.630    6428.212
110101111101    84.322    3412.940
101011111011    68.645    -2135.512
```

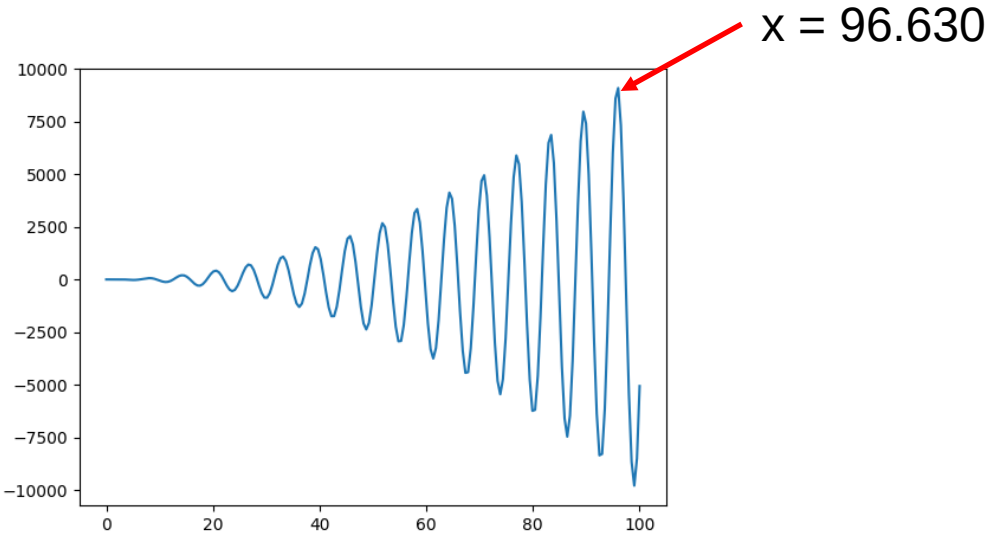

Projeto 1 - Algoritmo Genético
Programa: *lga02.py*

Data de entrega: 21-05-2018

Modifique o código do programa *lga01.py,* de forma que o programa leia os parâmetros do algoritmo genético a partir de uma arquivo de entrada *(lga.in*). O arquivo de entrada deve ter as seguintes informações:

pop_size
max_iter
p_cross
len_str
p_mut
seed
min_f
max_f
conv_factor
elitism_in
draw_turtle
plot_func

Os parâmetros *elitism_in, draw_turtle e plot_func* são variáveis booleanas que podem ser *True* ou *False*. O parâmetro *elitism_in* indica se o elitismo será considerado. O parâmetro *draw_turtle* é uma variável booleana e indica se as tartarugas serão desenhadas ou não. O último parâmetro *(plot_func)* indica se será gerado o gráfico da função ajuste. Esses três últimos parâmetros não estão no código *lga01.py* e devem ser incorporados no novo código.

Além disso, o novo código irá gerar um arquivo *lga.log* com as informações de cada geração (população, valor em *float* e valor da função ajuste). É similar ao que o programa *lga01.py* mostra na tela para cada geração, só que agora será gravado num arquivo .log. No final do arquivo *lga.log*, deve ser gravada uma linha com as informações do melhor indivíduo (string binária, valor em *float* e valor da função ajuste). O programa também gera um arquivo CSV, chamado *lga.csv*, com as seguintes informações:

Generation *Elite Member* *Mean Fitness Function* *Maximum Fitness Function*
...

O novo programa deve chamar-se *lga02.py* e tem que ser testado para as seguintes funções:

$f(x) = x^2$, no intervalo [1.25, 3.14] e *conv_factor = 0.45*,

$f(x) = 6x - x^2$, no intervalo [0, 6], e *conv_factor = 0.45*,

$f(x) = 7x - x^2 - 12$, no intervalo [0, 6] e *conv_factor = 0.6*,

$f(x) = x^2.\sin(x)$, no intervalo [0, 100] e *conv_factor = 0.0005*.

O programa deve ser entregue até o dia 14-05-2018 com um relatório sucinto descrevendo o desempenho do programa com as funções descritas no slide anterior. Devem ser testados diversos valores dos parâmetros de entrada do arquivo *lga.in*. Procurem o conjunto de parâmetros que gerem os melhores resultados para a localização do máximo das funções descritas no slide anterior.

A seguir temos a lista de programas da presente aula.
Lista de programas:

hexadec.py
lga01.py
random_loop.py
random_with_seed.py
test_function.py
touche.py

This text was produced in a HP Pavillon dm4 notebook with 6GB of memory, a 500 GB hard disk, and an Intel® Core® i7 M620 CPU @ 2.67 GHz running Windows 7 Professional. Text and layout were generated using PowerPoint 2007. Turtles drawings on slides 2 and 34 were generated with Turtle library. Plots on slides 32, 34, and 35 were generated by Matplotlib. The pizza charts on slides 16, 17, and 18 were generated with Excel 2007. The image on the first slide was taken from http://briandcolwell.com/2017/02/artificial-intelligence-the-big-list-of-things-you-should-know/.html on April 11, 2018. This text uses Arial font.

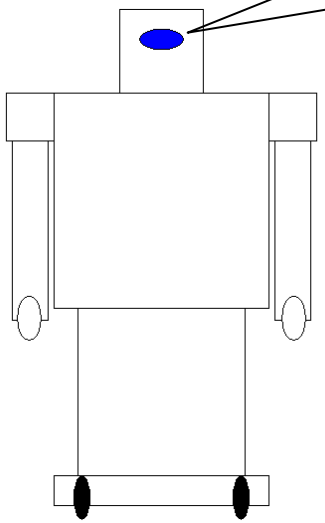

-BRESSERT, Eli. **SciPy and NumPy**. Sebastopol: O'Reilly Media, Inc., 2013. 57 p. Link

-DAWSON, Michael. **Python Programming, for the Absolute Beginner.** 3ed. Boston: Course Technology, 2010. 455 p.

-COLEY, David A. **An Introduction to Genetic Algorithms for Scientists and Engineers.** Singapore: World Scientific Publishing Co. Pte. Ltd., 1999. 227 p.

-EIBEN, A. E., SMITH, J. E**. Introduction to Evolutionary Computing. Natural Computing Series**. 2nd ed. Berlin: Springer-Verlag, 2015. 287 p. Link

-HACKELING G. **Mastering Machine Learning with scikit-learn**. Birmingham: Packt Publishing Ltd., 2014. 221 p. Link

-HETLAND, Magnus Lie. **Python Algorithms. Mastering Basic Algorithms in the Python Language.** 2ed. Nova York: Springer Science+Business Media LLC, 2010. 294 p. Link

-IDRIS, Ivan. **NumPy 1.5. An action-packed guide dor the easy-to-use, high performance, Python based free open source NumPy mathematical library using real-world examples. Beginner's Guide.** Birmingham: Packt Publishing Ltd., 2011. 212 p. Link

-LUTZ, Mark. **Programming Python.** 4ed. Sebastopol: O'Reilly Media, Inc., 2010. 1584 p. Link

-TOSI, Sandro. **Matplotlib for Python Developers.** Birmingham: Packt Publishing Ltd., 2009. 293 p. Link

Última atualização: 11 de abril de 2018.