

# Optimización usando Python

Dr. Luis Gerardo de la Fraga

Correo-e: [fraga@cs.cinvestav.mx](mailto:fraga@cs.cinvestav.mx)  
Departamento de Computación  
Cinvestav Zacatenco

19 de mayo, 2021

## Contenido:

1. Introducción a python
2. Problemas no lineales
3. Cómo se resuelven los problemas no lineales
4. Solución de problemas no lineales con heurísticas:
5. El algoritmo genético
6. La evolución diferencial

## ¿Por qué usar python?

- ▶ Es un lenguaje de alto nivel
- ▶ Es fácil construir programas rápidamente
- ▶ Es uno de los lenguajes más usados
- ▶ Es el lenguaje sugerido para programar en RaspBerryPi

## Lenguajes de alto nivel

- ▶ C es un lenguaje de nivel medio
- ▶ Los leguajes de alto nivel son interpretados
- ▶ No se definen tipos de datos
- ▶ Tienen una máquina de tiempo de ejecución (para uso de memoria con un recolector de basura)
- ▶ Se puede empotrar funciones en C dentro de python si se necesita eficiencia.

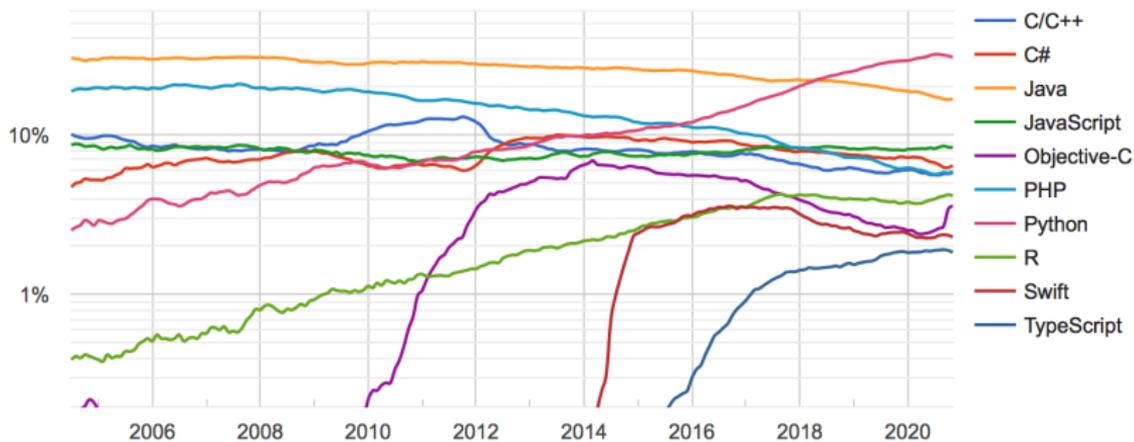
## Prototipado rápido

- ▶ Son ideales para realizar programas que procesan texto y generan texto
- ▶ Para generación dinámica de páginas WEB
- ▶ Si se tiene una idea, puede obtenerse un programa funcional en minutos u horas

Posición	Lenguaje	Uso %	Tendencia
1	Python	30.80 %	+1.8 %
2	Java	16.79 %	-2.3 %
3	JavaScript	8.37 %	+0.3 %
4	C#	6.42 %	-0.9 %
5	PHP	5.92 %	-0.2 %
6	C/C++	5.78 %	-0.2 %
7	R	4.16 %	+0.4 %
8	Objective-C	3.57 %	+1.0 %
9	Swift	2.29 %	-0.2 %
10	TypeScript	1.84 %	-0.0 %

<http://pypl.github.io/PYPL.html>

## PYPL Popularity of Programming Language



<http://pypl.github.io/PYPL.html>

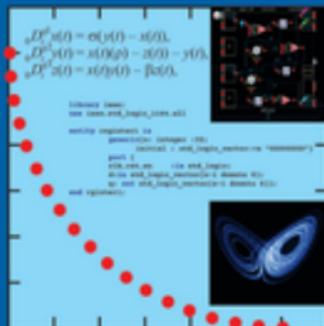
<http://www.raspberrypi.org/>



Se puede comprar en [www.newark.com.mx](http://www.newark.com.mx)

# Optimization of Integer/ Fractional Order Chaotic Systems by Metaheuristics and Their Electronic Realization

Esteban Tlelo-Cuautle, Luis Gerardo de la Fraga,  
Omar Guillén-Fernández and Alejandro Silva-Juárez



- ▶ Este libro salió a la venta este año 2021.
- ▶ Los programas que veremos son parte del contenido de este libro y están disponibles en:
- ▶ <https://cs.cinvestav.mx/~fraga/OptCode.tar.gz>

## Formas de usar python

- ▶ Existen dos formas principales para trabajar en python:
  1. A través de una interfaz como jupyter
  2. Usando la línea de comandos y un editor

## Jupyter

- ▶ Jupyter es un ambiente interactivo para ejecutar código dentro del navegador WEB
- ▶ Jupyter puede usarse con otros lenguajes de programación
- ▶ Dentro de las notas de jupyter se puede incorporar código, texto e imágenes

https:

`//jupyter-notebook.readthedocs.io/en/stable/notebook.html`

## En este taller usaré la línea de comandos

- ▶ Todos los programas de python son archivos
- ▶ Solo se necesita un editor (usaré “vi”) y la terminal
- ▶ Este el ambiente común de desarrollo de Unix o GNU/Linux
- ▶ Esta pensado para incorporar programas dentro de otros programas

## Python en 15 minutos

```
# Mi primer programa
# en python
#
i = 0
while i < 10 :
    i += 1
    print( i )
```

- ▶ Con # se escribe un comentario
- ▶ El inicio y fin de bloque se indican con la indentación
- ▶ No hay tipos
- ▶ La variable i es una variable entera porque está inicializada con un valor entero

```
#  
# Funciones en python  
#  
def f( x ) :  
    v = (x-1.0)*(x-4.0)  
    return v  
  
print( f(4.0) )
```

En un archivo que se llama  
funcion.py

```
#  
# Funciones en python  
#  
def f( x ) :  
    v = (x-1.0)*(x-4.0)  
    return v
```

En otro archivo:

```
import funcion  
  
x = -1.0  
while x < 4.1 :  
    print( x, funcion.f( x ) )  
    x += 0.5
```

## Paradigmas de programación en python

1. Imperativa
2. En objetos
3. Funcional

Archivo punto.py

```
class Punto :
    def __init__( self, x, y ) :
        self.x = x
        self.y = y

    def __add__( self, A ) :
        p = Punto(self.x+A.x,
                  self.y+A.y)
        return p

    def print( self ) :
        print( self.x, self.y )
```

En el archivo objetos.py

```
import punto

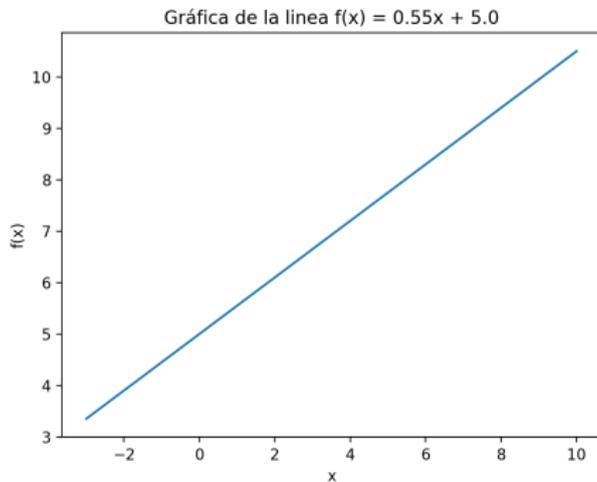
A = punto.Punto( 2, 3 )
A.print()

B = punto.Punto( 1, 2 )
B.print()

C = A + B
C.print()
```

## Una función lineal

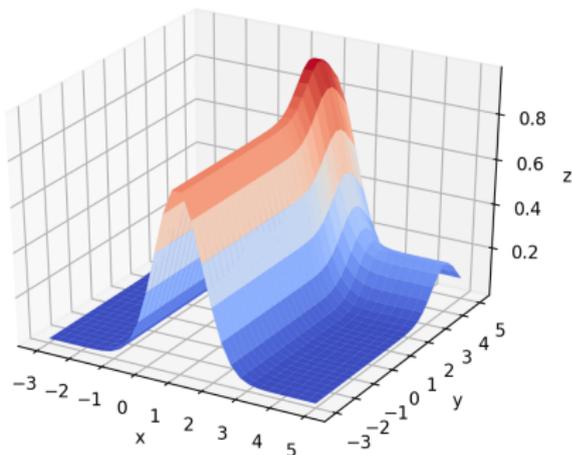
$$f(x) = a_1x + a_0$$



La dependencia puede ser lineal con respecto a los coeficientes, pero usando funciones no lineales:

$$f(x, y) = a_1 g_1(x, y) + a_0 g_0(x, y)$$

$$f(x, y) = a_1 \exp[-(x - 1)^2] + a_0 \exp[-(y - 4)^2]$$



Función  $f(x, y)$  con  $a_1 = 0.8$  y  $a_0 = 0.2$

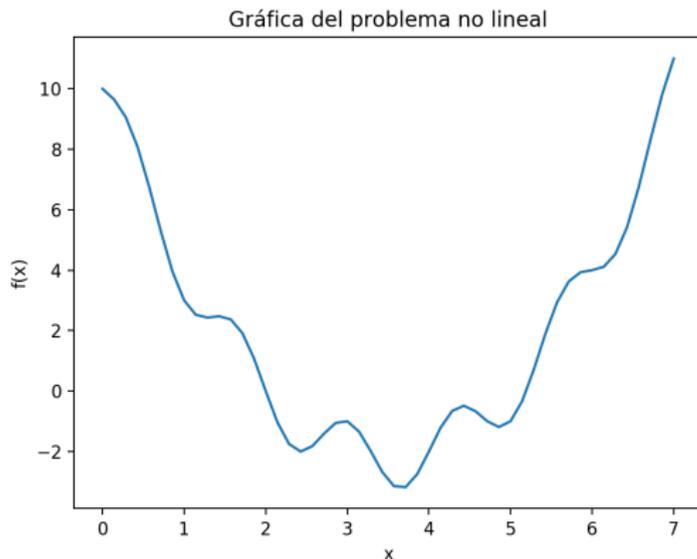
- ▶ Los problemas lineales son “fáciles” de resolver
- ▶ Su solución es equivalente al costo computacional de invertir una matriz.
- ▶ Otros problemas lineales se resuelven con la eigendescomposición de una matriz.

## Problemas no lineales

- ▶ Estos son “difíciles” de resolver
- ▶ De forma clásica se necesita una solución muy cerca de la solución del problema
- ▶ El problema no lineal se lineariza usando series de Taylor y
- ▶ se itera resolviendo cada vez un problema lineal hasta que converja.

Este es un problema no lineal:

$$\text{Minimizar: } f(x) = (x - 2)(x - 5) + \text{sen}(1.5\pi x)$$



## Para resolver un problema no lineal:

- ▶ Necesitamos una aproximación de la solución muy cerca de la solución del problema (¿Esto es una contradicción?)
- ▶ Podemos usar el método de Newton que aproxima la función no lineal con una aproximación lineal (usando los dos primeros términos de la serie de Taylor).
- ▶ Iteramos hasta la **convergencia**.

## La series de Taylor

$$f(\mathbf{x}) = \sum_{i=0}^{\infty} \frac{(\mathbf{x} - \mathbf{a})^i f^{(i)}(\mathbf{a})}{i!} \quad (1)$$

Usando los dos primeros términos de (1), obtenemos:

$$f(\mathbf{x}) \approx f(\mathbf{a}) + (\mathbf{x} - \mathbf{a})f'(\mathbf{a}) = f(\mathbf{a}) + \Delta \mathbf{a}f'(\mathbf{a}) \quad (2)$$

Y esta es una aproximación lineal de la función  $f$  alrededor del punto  $\mathbf{a}$

## El método de Newton

- ▶ Donde  $f$  es mínima, esta función es plana y su derivada debe ser igual a cero.
- ▶ Para encontrar el punto mínimo entonces calculamos la derivada de  $f$  e igualamos a cero para encontrar el valor de  $\mathbf{x}$ .
- ▶ La aproximación lineal de la derivada de  $f$  es:

$$f'(\mathbf{x}) \approx f'(\mathbf{a}) + (\mathbf{x} - \mathbf{a})f''(\mathbf{a}) = f'(\mathbf{a}) + \Delta\mathbf{a} f''(\mathbf{a}) \quad (3)$$

Igualando a cero se obtiene:

$$\Delta\mathbf{a} = \frac{-f'(\mathbf{a})}{f''(\mathbf{a})} \quad (4)$$

Y se itera  $\mathbf{a}_{i+1} = \mathbf{a}_i + \Delta\mathbf{a}$ , comenzando con un  $\mathbf{a}_0$

```
def f1(x):
    return (x-2.0)*(x-5.0) + math.sin( 1.5*math.pi*x )

def df1(x):
    return 2.0*x - 7.0 + 1.5*math.pi * math.cos( 1.5*math.pi*x )

def ddf1(x):
    return 2.0 - 1.5*math.pi*1.5*math.pi*math.sin(1.5*math.pi*x)

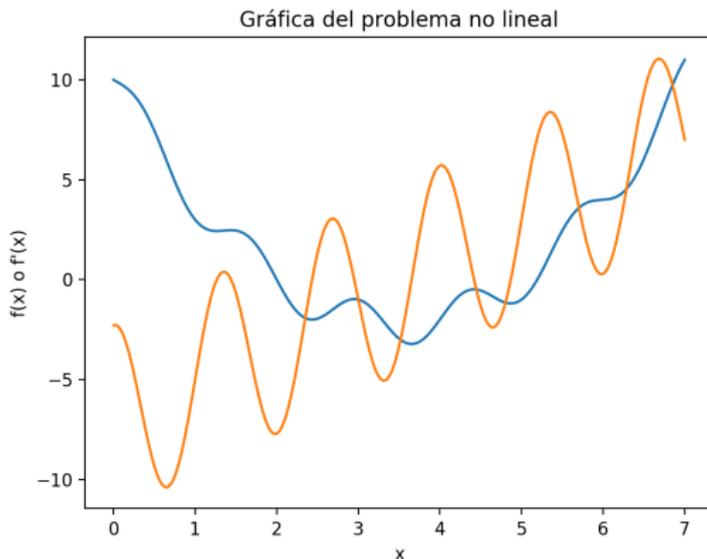
print( "0", x )
i = 1
while i < 20 : # 20 maximum iterations
    Deltaa = -df1(x)/ddf1(x)
    x += Deltaa
    print( i, x )

    if abs(Deltaa) < 1e-10 :
        break

    i += 1
```

Este es un problema no lineal:

$$\text{Minimizar: } f(x) = (x - 2)(x - 5) + \text{sen}(1.5\pi x)$$



## Una prueba del método de Newton

Usando el siguiente algoritmo:

1. Generar un número aleatorio en  $[0, 7]$
2. Usar este número como  $a_0$
3. Si la solución difiere en 0.001 del valor óptimo, se halló la solución al problema
4. Ir al paso 1

Se ejecutó 500 veces este algoritmo y tuvo un 13.8% de éxito.

Para el tipo de problemas no lineales y multimodales se justifica usar heurísticas.

## El algoritmo genético

- ▶ Utiliza un conjunto de soluciones (se le llama población)
- ▶ Combina soluciones para generar otras
- ▶ La solución que sobrevive es la mejor (la más apta)
- ▶ Usa los operadores de selección, cruza, mutación y elitismo
- ▶ La población guarda la “inteligencia” del algoritmo

## Pseudocódigo para un algoritmo genético

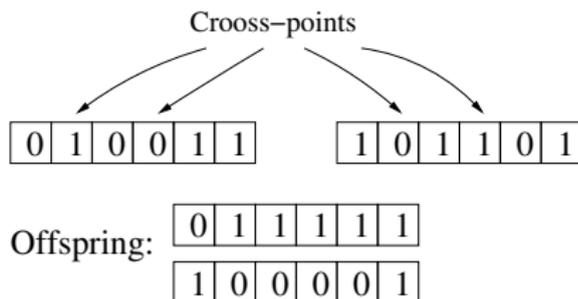
**Require:** Tamaño de la población  $\mu$ , número de generaciones  $g$ , probabilidad de cruce  $p_c$ , probabilidad de mutación  $p_m$ . La función  $f$  a optimizar.

**Ensure:** Una solución  $\mathbf{x}$  que minimiza  $f(\mathbf{x})$

- 1: Aleatoriamente crear la población inicial  $P = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_\mu\}$ .
- 2: Calcular la aptitud de los individuos.
- 3: **for**  $i \in [1, g]$  **do**
- 4:     **for**  $j \in [1, \mu/2]$  **do**                                   ▷  $\mu$  debe ser un número par
- 5:         Seleccionar dos individuos (llamados padres) que se reproducirán.
- 6:         Con probabilidad  $p_c$ , aplicar el operador de cruce
- 7:         Aplicar el operador de mutación con probabilidad  $p_m$ .
- 8:         Calcular la función de aptitud.
- 9:         Aplicar el mecanismo de elitismo.
- 10:     **end for**
- 11:     La nueva población de hijos reemplaza a los padres.
- 12: **end for**
- 13: Reportar el individuo con la mejor aptitud.

## Operadores genéticos

1. Selección: se usar el **torneo binario**, la población se barajea aleatoriamente y dos padres consecutivos se van escogiendo. Gana el de mejor aptitud.
2. Cruza de dos puntos:



## Prueba del algoritmo genético

- ▶ El espacio de búsqueda fue  $[0, 7]$
- ▶ 20 individuos y 30 generaciones
- ▶ Se codificó cada individuo en 10 bits
- ▶ La solución es exitosa si  $|x - 3.65288744| < 0.05$ .
- ▶ Tuvo una tasa de éxito de 97.2 %
- ▶ Esto requirió  $20 \times 30 = 600$  evaluaciones de la función objetivo
- ▶ El AG solo requiere la función objetivo

## La evolución diferencial

- ▶ Usa números reales en su representación
- ▶ Realiza un mejor trabajo que el algoritmo genético
- ▶ Se puede usar una condición automática de paro

```

1: initialize( $P = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_\mu\}$ )
2: evaluate( $P$ )
3:  $k = 0$ 
4: repeat
5:   for  $i = 1$  to  $\mu$  do
6:     Let  $r_1, r_2$  and  $r_3$  be three random integers in  $[1, \mu]$ , such that  $r_1 \neq r_2 \neq r_3$ 
7:     Let  $j_{\text{rand}}$  be a random integer in  $[1, n]$ 
8:     for  $j = 1$  to  $n$  do
9:       
$$x'_j = \begin{cases} x_{r_3,j} + F(x_{r_1,j} - x_{r_2,j}) & \text{if } U(0,1) < R \text{ or } j = j_{\text{rand}} \\ x_{i,j} & \text{otherwise} \end{cases}$$

10:      if  $x'_j < l_j$  or  $x'_j > u_j$  then ▷ Check bounds
11:         $x'_j = U(0,1)(u_j - l_j) + l_j$ 
12:      end if
13:    end for
14:    if  $f(\mathbf{x}')$  <  $f(\mathbf{x}_i)$  then
15:       $\mathbf{x}_i = \mathbf{x}'$ 
16:    end if
17:  end for
18:  for  $i = 2$  to  $\mu$  do
19:    mín = mejor individuo
20:    máx = peor individuo
21:  end for
22: until ( $\text{máx} - \text{mín}$ ) <  $s$  or  $k > g$ 

```

## Una prueba

- ▶ Con 16 individuos
- ▶ 30 generaciones
- ▶ Constante de diferencias igual a 0.8
- ▶ Constante de recombinación igual a 0.6
- ▶ Intervalo de búsqueda en  $[0, 7]$
- ▶ Después de 500 ejecuciones obtuvo una tasa de éxito del 100 %
- ▶ Un éxito se cuenta si  $|x - 3.65288744| < 10^{-4}$ .

## Resumen

1. Se estudió el lenguaje de programación python
2. Se describió un problema no lineal y multimodal
3. Se revisó el método de Newton,
4. el algoritmo genético y
5. la evolución diferencial

## Resultados

Método	Tasa éxito	Éxito
Newton con inicio aleatorio	13.8 %	$ x - 3.65288744  < 0.001$
Algoritmo genético	97.2 %	$ x - 3.65288744  < 0.05$
Evolución diferencial	100.0 %	$ x - 3.65288744  < 10^{-4}$

## Más material

- ▶ Mi correo-e: [fraga@cs.cinvestav.mx](mailto:fraga@cs.cinvestav.mx)
- ▶ Página web: <https://delta.cs.cinvestav.mx/~fraga>
- ▶ Programas del libro: <https://delta.cs.cinvestav.mx/~fraga/OptCode.tar.gz>
- ▶ pymoo (<https://pymoo.org>), para resolver problemas multiobjetivo en python. Este paquete provee varios algoritmos evolutivos y una guía de uso para resolver los problemas que tengamos a mano.

¡Gracias!