



Wydział  
Informatyki

# Algoritmos de la Forma Greedy

---

**Jose Lucha (1890), Leonel Contreras (18797)**

# Agenda

1. Algoritmo Greedy
  - 1.1 Ideas Basicas
  - 1.2 Por qué considerar el metodo?
  - 1.3 Ejemplos importantes
  - 1.4 Tipos de Hill Climbing
  - 1.5 Referencias

## Ideas Basicas

Tecnica de resolucion de problemas que toma decisiones localmente optimas con la esperanza de obtener una solucion globalmente optima

Funciona para problemas que satisfacen la condicion de subestructura optima. n problema tiene una subestructura optima si una solucionoptima del problema global contiene las soluciones optimas a sus sub-problemas.

## Ideas Basicas

En muchos problemas, la estrategia greedy no da una solución óptima ya que toma decisiones basadas en la información de cada paso y no considera el problema en conjunto. La elección hecha por un algoritmo que use la técnica greedy depende de las elecciones que ha hecho hasta el momento, pero no es consistente con las decisiones futuras.

## Por qué considerar el metodo?

Como es sabido, este metodo no aplica para varios tipos de problemas. Sin embargo, se implementa ya que aproxima una solucion optima en un tiempo considerable -o en una cantidad de pasos considerable-.

## Hill Climbing

El metodo de Hill Climbing es una tecnica de optimizacion que pertenece la familia de busqueda local. Esta tecnica empieza con una solucion arbitraria al problema y se mueve de solucion en solucion en el espacio de soluciones candidato al aplicar cambios locales.

El metodo Hill Climbing encuentra soluciones optimas para problemas convexos. Es decir, miniza funciones convexas y conjuntos convexos

## Hill Climbing

La diferencia entre el hill climbing y los metodos de descenso gradiente en una funcion  $f : R^n \mapsto R$  es que el metodo de hill climbing ajusta uno de los componentes  $x_i$  del vector  $x \in R^n$  y determina si el cambio mejora o no  $f(x)$ . Mientras que los metodos de descenso gradiente ajustan todas las componentes del vector de acuerdo al gradiente.

## Funcionamiento del algoritmo

1. Sean  $f : R^n \rightarrow R$  y  $x_0$  un punto del dominio.
2. Evaluamos  $f(x_0)$  y lo establecemos como la opción óptima.
3. Seleccionamos, bajo algún criterio, un punto en la vecindad de  $x_0$  y evaluamos la función en este punto.
4. Si este nuevo punto genera una mejor solución para la función lo designamos como nueva opción óptima y repetimos el proceso. Si la solución no es mejor a nuestro  $x_0$  seleccionamos un nuevo punto.

## Debilidades del metodo

Debido a la idea detras del proceso del metodo el desempeño de este depende mucho de el  $x_0$  elegido y la geometria de la funcion.

1. Maximos y minimos locales: Sabemos que este tipo de puntos son las cotas optimas en una region, pero no necesariamente de toda la funcion. Debido a esto si el metodo hill climbing se topa con uno de estos puntos lo considerara la solucion optima para el problema.
2. Planicies: Diremos que una planicie es una region constate dentro de la funcion donde estos puntos contantes son maximo o minimo local. Debido a que el valor de la funcion no cambia dentro de esta region el metodo se detendra en esta y considerara la constante como solucion optima y algun punto de la planicie como el punto que la genera.

## Hill Climbing Simple

1. Sea  $x_0$  nuestro punto inicial y designamos  $f(x_0)$  como a mejor solución.
2. Nos desplazamos en una dirección fija y evaluamos la función en este punto.
3. Si la solución en este punto es mejor designamos este nuevo punto como mejor solución y repetimos el proceso.
4. De lo contrario nos desplazamos en la dirección contraria y evaluamos de nuevo.

# Implementacion

]Hill1.PNG

Rysunek: Metodo Hill Climbing Simple

## Implementacion


```
else:

    if f(x_0+tol)<f(x_0):
        dire = tol
        nextstep = f(x_0+dire)
        while nextstep < best:
            best = nextstep
            dire = dire+tol
            it = it + 1
            if it > it_max:
                return 'Maximo de iteraciones alcanzado. Ultima solucion: ', x_0+dire
            nextstep = f(x_0+dire)

    else:
        dire = -tol
        nextstep = f(x_0+dire)
        while nextstep < best:
            best = nextstep
            dire = dire-tol
            it = it + 1
            if it > it_max:
                return 'Maximo de iteraciones alcanzado. Ultima solucion: ', x_0+dire
            nextstep = f(x_0+dire)
print('Numero de iteraciones: ',it)
return 'La solucion optima se encuentra aproximadamente en: ', x_0+dire
```

Rysunek: Metodo Hill Climbing Simple

## Ejemplo



```
Numero de iteraciones: 25707963  
( 'La solucion optima se encuentra aproximadamente en: ', -1.57079639993998835)  
Numero de iteraciones: 5707963  
( 'La solucion optima se encuentra aproximadamente en: ', 1.570796399976084)
```

Rysunek: Hill Climbing Simple Aplicado a  $\sin(x)$

## Hill Climbing Estocastico


1. Sea  $x_0$  nuestro punto inicial y designamos  $f(x_0)$  como a mejor solucion.
2. Dentro de una vecindad de  $x_0$  seleccionamos aleatoriamente un nuevo punto y evaluamos la funcion en este punto.
3. Si la solucion es mejor a la anterior seleccionamos este puento como la nueva mejor solucion.
4. De lo contrario escoger nuevamente un numero aleatorio dentro del intervalo definido.

## Implementacion

```
#Hill climbing estocastico
#obj_max = False --> minimo
#obj_max = True --> Maximo
def Stochastic_hill_climbing(x_0,f,obj_max,tol,maxit):
    best = f(x_0)
    x = np.random.uniform(x_0-tol, x_0+tol)
    it = 0
    if obj_max == True:
        while it < maxit:
            if f(x)>f(x_0):
                x_0 = x
                x = np.random.uniform(x_0-tol, x_0+tol)
            else:
                x = np.random.uniform(x_0-tol, x_0+tol)
                it = it+1
    else:
        while it < maxit:
            if f(x)<f(x_0):
                x_0 = x
                x = np.random.uniform(x_0-tol, x_0+tol)
            else:
                x = np.random.uniform(x_0-tol, x_0+tol)
                it = it+1

    return 'La solucion optima se encuentra aproximadamente en:', x_0
```

## Ejemplo



Rysunek: Hill Climbing Estocastico Aplicado a Sin(x)

## Comentarios y Recomendaciones

1. Utilizar este metodo con un punto de inicio cercano a la solucion aproximada.
2. Tomar en cuenta si se evalua una region adecuada.
3. De no obtener una respuesta satisfactoria reevaluar el punto de inicio o el numero de iteraciones.
4. La calidad de la aproximacion de la respuesta depende de la tolerancia e iteraciones utilizadas.

## Referencias

1. S. Russell, P. Norvig, (2020) Artificial intelligence: a modern approach ,Prentice Hall, New Jersey
2. O. Mbaabu (16 de diciembre, 2020) Understanding Hill Climbing Algorithm in Artificial Intelligence. Obtenido de:  
<https://www.section.io/engineering-education/understanding-hill-climbing-in-ai/>