

Introducción a Optimización

Semestre 2011-2

Definición de Optimización

- Según Bonnans et. al.:
 - Dado un conjunto X de variables numéricas reales y una función $f : X$, encontrar una serie de valores $x^* \in X$ que, para cualquier otro x : $f(x) \geq f(x^*)$
- ¿Qué significa esto?

En español...

- Encontrar la solución que minimiza una *función objetivo*.

Pero...

- Según Bonnans et. al.:
 - Dado un conjunto X de variables numéricas **reales** y una función $f : X$, encontrar una serie de valores $x^* \in X$ que, para cualquier otro x : **$f(x) \geq f(x^*)$**



- ¿Valores enteros, complejos, discretos?
- ¿Maximizar?

Terminología

- Función objetivo:
 - La función a optimizar.
 - Uno o más variables.
 - Usualmente restringidas a rangos de valores.
 - Pueden ser discretas (enteras) o continuas.
 - Define el Espacio de Solución.
 - Ejemplos.
 - $f(x) = x^2$
 - $f(x,y,z) = ?$
 - También conocidas como **Cajas Negras**

Parecido al problema de SAT

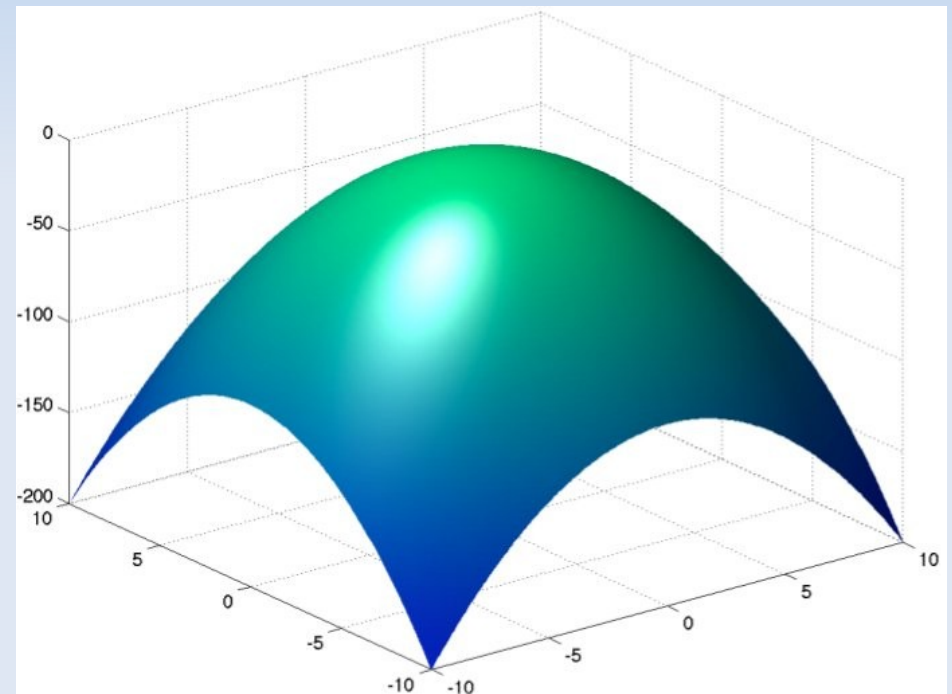
- La función objetivo es análogo al enunciado a satisfacer.
- Se han aplicado algoritmos de optimización como resolvedores SAT.
 - Algoritmos genéticos (ya están en forma binaria).
- Pero, hay una diferencia importante entre satisfacer un enunciado y optimizar una función.

Terminología

- Espacio de Solución:
 - Conjunto de series de valores que proveen una *solución posible* (como los modelos en el problema SAT) a la función objetivo.

Espacio de Solución Convexo

- De Jong (1975)
 - $f(X) = - \sum x^2$
 - Modificado para que sea máximo.
- Todo modelo se puede 'conectar' a otro por una línea recta.
- La función más fácil de optimizar.



¿Por qué es la más fácil?

Algoritmo de Optimización 1: Steepest Descent


- A.k.a. Descenso por **Gradiente** (Gauss)
 - En caso de maximizar, es Ascenso
- Algoritmo:
 - Se propone una solución X_i inicial al azar.
 - Se actualiza a X_i con:
 - $X_{i+1} \leftarrow X_i - a \nabla f(X_i)$
 - a es un número real pequeño ($a \ll 0$).
 - En caso de ascenso, a es negativo.
 - $\nabla f(X_i)$ es la gradiente de f aplicando la solución X_i
 - Hasta X_i **converja**.

Gradiente

- Indica la dirección del mayor incremento de cambio en una función.
- ∇f es un vector de derivadas parciales:
 - $\partial f / \partial x_1, \partial f / \partial x_2, \partial f / \partial x_3, \dots, \partial f / \partial x_n$
- Por lo tanto, $\nabla f(X_i)$:
 - $\partial f(x_{i,1}) / \partial x_1, \partial f(x_{i,2}) / \partial x_2, \partial f(x_{i,3}) / \partial x_3, \dots, \partial f(x_{i,n}) / \partial x_n$
- $|\nabla f(X_i)|$ es la magnitud del vector.

Ejemplo


$$f(x,y) = -x^2 - y^2$$



Adelantémonos un poco...


Otro Espacio de Solución: Rosenbrock

- $f(X) = -\sum 100(x_{d-1} - x_d^2)^2 + (1 - x_d)^2$
 - d es el índice de variable dentro de X
- Diseñado para 'engañar' al algoritmo a entrar a un área de *óptimos locales* con el *óptimo global* escondido.




Otro Espacio de Solución: Rastrigin

- $f(X) = -10D - \sum x_d^2 - 10\cos(2\pi x_d)$
 - D es el número de variables
- Como De Jong, pero con más 'topes'.




Otro Espacio de Solución: Schaffer F6

$$Z = -0.5 - \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{1 + 0.01(x_1^2 + x_2^2)}$$



¿Problemas con Descenso Gradiente?

¿Que tal con éste?



Entonces...

- No funciona en funciones no derivables (no continuas, aka discretas).
- Se atasca en óptimos locales fácilmente.
- Se **alenta** al estar cerca de algún óptimo.
- El tiempo computacional para el cálculo de la gradiente es exponencial al número de variables.
-
- Pero... **garantiza** resultado correcto en un espacio de solución convexo.

1er Problema: Funciones Discretas

- Hay tal cosa como Gradiente Discreta:
 - Dado un estado x_i , busca el estado *vecino* que da el mayor valor a la función, y es mayor a x_i .
- Un *vecino* de x_i es el estado en el que todas las variables de x_i sólo cambiaron de índice uno o menos.
 - Si $x_i = \{1,2,3\}$, x_{i+1} puede ser:
 - $\{0,2,3\}$ vecino
 - $\{2,1,2\}$ vecino
 - $\{4,2,3\}$ no es vecino

Algoritmo de Optimización 2: Hill Climbing

- Es Ascenso por Gradiente, pero en forma discreta.
- La búsqueda del vecino de mayor valor también es exponencial por número de variables.
 - Todas las posibles *combinaciones* de valores en diferencia a 1 de los valores actuales.
- Esta búsqueda de combinaciones es la razón por la que a los problemas de optimización con variables discretas se les conoce como **Optimización Combinatoria**.

2do Problema: Óptimos Locales

- Cada vez que se crea que se ha llegado a un óptimo, se 'desatasca' al algoritmo cambiando el estado utilizando alguna *regla de cambio*.


Algoritmo de Optimización 3: Templado Simulado

- A.k.a. Simulated Annealing.
- *Regla de Cambio:*
 - Se comienza con un monto de 'energía' inicial.
 - Al momento de cambio, se propone un nuevo estado *al azar*, dentro de un rango de valores definido por el monto de 'energía' actual.
 - En cada cambio, la 'energía' se disminuye.
 - La búsqueda termina cuando ya no haya 'energía'.
- Inspirado por el proceso de endurecimiento de acero.

Templado Simulado

- El monto de 'energía' tiene que ser grande para garantizar convergencia en un óptimo global.
 - Pero también aumenta el tiempo de convergencia.

3er Problema: Lento al Llegar a Óptimo



Entonces...

- Hacer más grande al parámetro a de:
 - $X_{i+1} \leftarrow X_i - a\nabla f(X_i)$
 - No tan grande para que no *sobredispere* el óptimo.
- O hacerlo dinámico:
 - Incrementarlo cuando $|\nabla f(X_i)|$ se hace pequeño.
- O reemplazarlo completamente...

Método Newton-Raphson

- Asume que se ha llegado al óptimo global cuando: $|\nabla f(X_i)| = 0$.
 - El problema es encontrar las raíces de $\nabla f(X_i)$.
- Encuentra la segunda derivada:
 - $H_f = \partial^2 f / \partial x_1 \partial x_2 \dots \partial x_D$
- Así la actualización es:
 - $X_{i+1} \leftarrow X_i - H_f^{-1}(X_i) \nabla f(X_i)$
- Y **converge** cuando $|\nabla f(X_i)| = 0$.

Método Newton-Raphson

- Es lento... muy lento.
 - Sigue siendo exponencial, pero a mayor grado:
 - Cálculo de segundas derivadas, además de primeras derivadas.
- De nuevo, la función tiene que ser derivable.
 - Tiene versión discreta, pero requiere de aún más tiempo que la versión continua.

Otras Opciones para el Cálculo del 'Siguiente Paso'

- Es en sí un problema de optimización.
 - Encontrar el 'paso óptimo' dado x_i y $f(X)$ que asegure que nos lleve más cerca a la convergencia, en los menos pasos posibles.
- Una opción popular es el uso de las condiciones Armijo-Wolfe:
 - El nuevo paso asegura una disminución 'suficiente' de $f(X)$ en una dirección en el que el gradiente se disminuye 'suficientemente'.

¿Los tres problemas fueron resueltos?

¿Se requieren resolver?

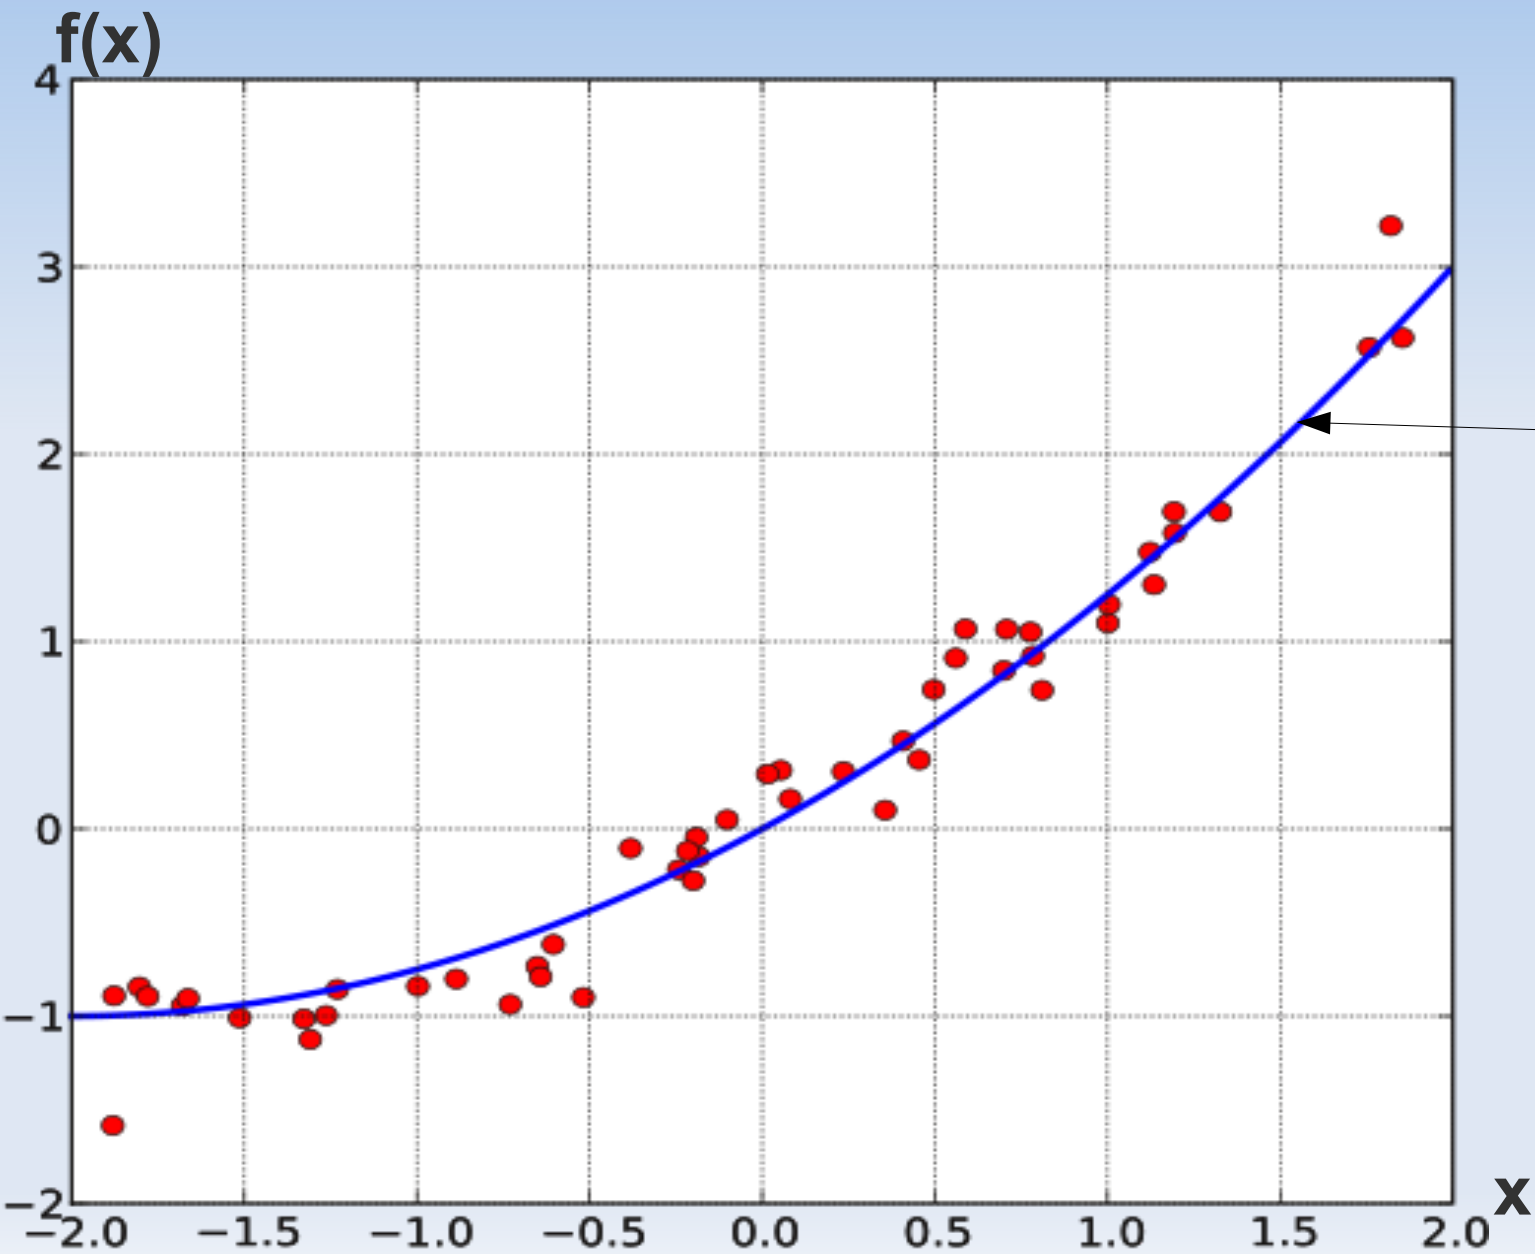
1a Lección de Optimización

- Conoce el espacio de solución.
 - ¿Es convexo?
 - Si no, ¿lo podemos hacer convexo?

Ejemplo: Mínimos Cuadrados

- Se tiene una serie de puntos, a los cuales se les quiere encontrar un modelo que los describa.
- Se propone un orden de modelo, y se requiere que se encuentre los coeficientes del modelo con menor error al describir los puntos.

Mínimos Cuadrados



Se propuso un orden de 2o grado:

$$y(x) = Ax^2 + Bx + C$$

Funciones Objetivo Posibles

- Donde
 - (x_i, y_i) es un punto
 - $\hat{y}_i[x_i, A, B, C]$ es el estimado de y_i del modelo utilizando los coeficientes A , B , y C
- 1a alternativa: $f(A, B, C) = \sum |y_i - \hat{y}_i[x_i, A, B, C]|$
 - ¿Proporciona un espacio de solución convexo?

Funciones Objetivo Posibles

- 2a alternativa: $f(A,B,C) = \sum (y_i - \hat{y}_i[x_i, A, B, C])^2$
 - ¿Proporciona un espacio de solución convexo?
- De hecho, utilizando esta función objetivo, se ha encontrado que la solución es única:
 - **$(X'X)B=X'Y$**
 - X es el vector de x_i , Y el de y_i .
 - B es el conjunto de coeficientes óptimos.
 - Cómo se llega a esa ecuación es tema de otro curso, (Wikipedia es su amigo).

Por cierto...

¿Cuál fue la diferencia importante entre optimizadores y resolvers SAT?

Siguiente Clase

- Hablaremos de:
 - Convergencia
 - Clasificación (informal) de Algoritmos de Optimización