

FUNDAMENTO DE OPTIMIZACIÓN 1S-2024
RESUMEN DE CLASES

CLASE 1 (18/03/2024) - INTRODUCCIÓN AL CURSO Y REPASO

Para introducir el curso comenzamos con una presentación hecha por el prof. Marcelo Fiori donde se muestran diversos ejemplos de optimización en problemas de ingeniería (para ver lo slides puede hacer click [AQUI](#)).

Luego comenzamos con un repaso general de algunos conceptos que se ven mayoritariamente en Cálculo 2 como ser:

- (1) El diferencial df_p , la matriz Jacobiana $Jf(p)$, el gradiente $\nabla f(p)$, derivadas parciales $\frac{\partial f}{\partial x_i}(p)$ y direccionales $\frac{\partial f}{\partial v}(p)$. Recordamos algunas importantes propiedades de las derivadas direccionales:
 - (a) $\frac{\partial f}{\partial v}(p) > \frac{\partial f}{\partial w}(p)$ entonces para algún $\epsilon > 0$ se cumple $f(p + vt) > f(p + wt)$ para todo $t \in (0, \epsilon)$.
 - (b) Si $\nabla f(p) \neq 0$, $v_0 = \frac{\nabla f(p)}{\|\nabla f(p)\|}$ entonces $\frac{\partial f}{\partial v_0}(p) > \frac{\partial f}{\partial v}(p)$, $\forall v : \|v\| = 1$ (se lee: el gradiente es la dirección de mayor crecimiento).
 - (c) Si $\nabla f(p) \neq 0$, $v_0 = -\frac{\nabla f(p)}{\|\nabla f(p)\|}$ entonces $\frac{\partial f}{\partial v_0}(p) < \frac{\partial f}{\partial v}(p)$, $\forall v : \|v\| = 1$ (se lee: el gradiente opuesto es la dirección de mayor decrecimiento).
 - (d) El signo de $\frac{\partial f}{\partial v}(p)$ indica crecimiento/decrecimiento (si es positivo/negativo entonces la función en p crece/decrece en la dirección v).
- (2) Condición necesaria de optimalidad: $\nabla f(x^*) = 0$ para x^* mínimo local.
- (3) Ejemplo: Minimizar $f_{\mathbb{R}^2} \rightarrow \mathbb{R}$ dada por $f(x, y) = x^2 + y^2$
 - sin restricciones (aprovechamos para repasar conceptos como curvas de nivel y vimos que el gradiente es perpendicular a las curvas de nivel)
 - con una restricción del tipo $g(x, y) = 0$ (método de los multiplicadores de Lagrange).

Comentario: El método de los multiplicadores de Lagrange sirve para minimizar una función $f(x)$ sujeto a la restricción del tipo $g(x) = 0$ (donde $f, g : \mathbb{R}^n \rightarrow \mathbb{R}$ son de clase C^1). Se considera la función Lagrangiana (o Lagrangiano) $F(x, \lambda) = f(x) - \lambda g(x)$. El Teorema de los multiplicadores de Lagrange dice que si f tiene mínimo en $x = x^*$ y $\nabla g(x^*) \neq 0$ entonces existe un λ^* que verifica $\nabla F(x^*, \lambda^*) = 0$. Entonces la idea es encontrar todos los (x, λ) para los cuales $\nabla F = 0$ y chequear esos posibles x cual minimiza f (debemos estar seguros que f tenga mínimo absoluto en la región considerada sino solo vamos a encontrar un mínimo relativo).

Lectura introductoria recomendada sobre el tema:

- Unas notas (en las páginas 1-3 ya da una idea básica del método)
- Wikipedia

CLASE 2 (22/03/2024) - REPASO Y MÁS EJEMPLOS

Repasamos algunas propiedades de la Jacobiana (similares a las propiedades que cumple la derivada para funciones de una variable): $J(f+g)(p) = Jf(p) + Jg(p)$, $J(fg)(p) = f(p)Jg(p) + Jf(p)g(p)$ y $J(f \circ g)(p) = Jf(g(p)) \cdot Jg(p)$ (cuando las operaciones tienen sentido y las funciones son diferenciables en todos los lados donde se necesita).

Norma y productos internos en espacios vectoriales. Como ejemplos importantes vimos:

- El producto interno usual de \mathbb{R}^n : $\langle x, y \rangle = x^t y$, que da lugar a la norma euclídea (denotada por $\|x\|_2$ o simplemente por $\|x\|$ cuando no hay peligro de ambigüedad).
- El producto interno en $\mathbb{R}^{n \times m}$: $\langle A, B \rangle = \text{tr}(A^t \cdot B)$, que da lugar a la norma de Frobenius $\|A\|_F = \sum_{i,j} A_{i,j}^2$ (juega un papel importante en aplicaciones prácticas).
- La norma espectral: $\|A\|_2 = \max\{\|Ax\| : \|x\| = 1\}$ que cumple la propiedad $\|Ax\|_2 \leq \|A\|_2 \cdot \|x\|_2$ (esa propiedad la hace muy útil para probar resultados teóricos). Esta norma también se denota simplemente por $\|A\|$ si no hay peligro de ambigüedad y la propiedad mencionada se puede escribir como $\|Ax\| \leq \|A\| \cdot \|x\|$. Es importante observar que $\|A\|$ es un número real que no depende de x .

Luego vimos ejemplos varios de cálculos de gradiente, mostrando dos formas de cálculo:

- Usando la unicidad de la Jacobiana y la propiedad $\|Ax\| \leq \|A\| \cdot \|x\|$ para acotar el resto.
- Usando la regla de la cadena (quedó como ejercicio completar detalles).

Los ejemplos fueron:

- Cálculo del gradiente de una forma cuadrática $q : \mathbb{R}^n \rightarrow \mathbb{R}$, $q(x) = x^t A x$.
- Cálculo del gradiente de una función $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $f(x) = \|Ax\|^2$.

Para finalizar mostramos una forma de chequeo para el cálculo del gradiente, aproximando las derivadas parciales usando la definición de límite.

Comentario 1: el contenido corresponde al video 1 del 2023, más un poco de contenido extra como multiplicadores de Lagrange, la norma espectral y vimos con un poco más de detalle el cálculo del gradiente usando la unicidad del Jacobiano y la propiedad de la norma espectral, no solo para el ejemplo de mínimos cuadrados sino también para formas cuadráticas. Para el ejemplo de mínimos cuadrados también mostramos como calcular el gradiente usando la regla de la cadena para Jacobianos.

Comentario 2: Para aquellos estudiantes que no pudieron asistir a clases y están utilizando los videos del curso anterior recomiendo escoger la opción 1 del obligatorio 1 para el cual alcanza con lo visto en el video 1 del 2023.

CLASE 3 (01/04/2024)

CLASIFICACIÓN DE MÉTODOS ITERATIVOS Y OPTIMIZACIÓN EN UNA VARIABLE

Definimos método iterativo y los clasificamos según su velocidad de convergencia en: lineales, superlineales y cuadráticos (convergencia cuadrática implica convergencia superlineal que a su vez implica convergencia lineal).

Vimos algunos métodos de optimización en una variable como el Grid Search, el método de bisección (para raíces) y el método Golden Section.

Video del 2023 relacionado: video 2.

CLASE 4 (05/04/2024)

OPTIMIZACIÓN EN UNA VARIABLE Y OPTIMIZACIÓN CONVEXA

Optimización en una variables (continuación):

- Vimos un ejemplo explícito del Golden Section Search para hallar el mínimo de la función $f(x) = x^3 + 6x^2 - 3x$ en el intervalo $[0, 1]$ (mostramos como construir una tablita de los $\{x_n, y_n, z_n\}$ para las primeras iteraciones del método). Si llamamos $p_n = \frac{x_n + z_n}{2}$ probamos que la convergencia $p_n \rightarrow x^*$ es lineal (más concretamente probamos que $\frac{e(p_{n+1})}{e(p_n)} = 1/\Phi$ donde Φ es el número áureo).
- Para finalizar vimos el método de Newton (para f de clase C^3 y $f''(x^*) \neq 0$) donde se construye la secuencia siguiendo el método de la parábola tangente, obteniendo $x_{n+1} = x_n - \frac{f'(x_n)}{f''(x_n)}$. Probamos que si el método comienza de un punto x_0 suficientemente cercano al mínimo x^* el método tiene convergencia (al menos) cuadrática.

Optimización convexa:

- Definimos conjuntos convexos y vimos varios ejemplos: los intervalos reales, las bolas en \mathbb{R}^n (con cualquier norma), los conjuntos afines (subespacios vectoriales trasladados), semiespacios, intersección de convexos es convexo, poliedros convexos (por ser intersección finitas de semiespacios), la envolvente convexa de un subconjunto de puntos de \mathbb{R}^n .
- Definimos funciones convexas, vimos la interpretación geométrica y dejamos como ejercicio probar que una función es convexa si y solo si su epígrafo es un conjunto convexo. Probamos el Teorema que establece que un mínimo relativo de una función convexa debe ser también un mínimo absoluto.

Videos del 2023 relacionados: videos 2 y 3.

CLASE 5 (08/04/2024)
OPTIMIZACIÓN CONVEXA

Funciones convexas y estrictamente convexas, como distinguias por su epigrafo. Funciones cóncavas. Varios ejemplos de funciones convexas o cóncavas. Construcciones: combinación lineal convexa de funciones convexas es convexa, máximo de funciones convexas es convexa y $f(Ax + b)$ es convexa si $f : \Omega \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ lo es. Restricción de funciones convexas a segmentos sigue siendo convexa (en el caso que el dominio de f sea un espacio afín esto vale también para restricción a rectas). El subconjunto de nivel $H_c = \{x \in \Omega : f(x) \leq c\}$ es un conjunto convexo si $f : \Omega \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ es una función convexa (el recíproco no vale). Convexidad y diferenciabilidad: recordamos que era que una función fuese de clase C^k para $k \geq 1$. Vimos que una función diferenciable y convexa verifica $f(z) \geq f(x) + \nabla^t f(x) \cdot (z - x)$. Probamos que en el caso de funciones convexas y diferenciable vale que x^* es mínimo local si y solo si $\nabla f(x^*) = 0$.

Videos del 2023 relacionados: videos 3 y 4.

CLASE 6 (12/04/2024)
OPTIMIZACIÓN CONVEXA Y MÉTODOS DE DESCENSO POR GRADIENTE

Enunciamos: si $f \in C^2(\Omega)$ entonces si la matriz Hessiana $\nabla^2 f(x)$ es semi-definida positiva (definida positiva) para todo $x \in \Omega$ entonces f es convexa (convexa estricta). Repaso: cuando f es de clase C^2 la matriz Hessiana es simétrica y por el teorema espectral sus valores propios son todos positivos entonces puede clasificarse en 5 casos: definida positiva/negativa, semi-definida positiva/negativa e indefinida. Vimos como expresar esa condición en relación a su forma cuadrática asociada. Métodos iterativos: cuándo decimos que es un método de descenso, cuándo decimos que es un método de descenso por gradiente. En métodos de descenso por gradiente $x_{k+1} = x_k + \alpha_k d_k$ hace falta definir tres parámetros: elección de dirección d_k (se toman direcciones de decrecimiento, o sea, aquellas direcciones cuyas derivadas direccionales $\frac{\partial f}{\partial d_k}(x_k) = \nabla^t f(x_k) \cdot d_k$ son negativas). Las formas comunes de conseguirlo es tomando $d_k = D_k \nabla f(x)$ donde D_k es una matriz simétrica definida positiva. Vimos algunos casos particulares: Steepest descent tomando $D_k = I$ (vimos que es bastante simple de implementar pero a veces tiene el problema del zigzagueo por causa de la curvatura). Newton tomando $D_k = (\nabla^2 f(x_k))^{-1}$ (esto soluciona el problema de la curvatura pero tiene el inconveniente que a veces es demasiado costoso). Diagonal scaling tomando $D_k = \text{diag}(d_{k1}, \dots, d_{kn})$ matriz diagonal $n \times n$ (para que sea una dirección descenso se debe cumplir $\sum_{i=1}^n d_{ki} (\frac{\partial f}{\partial x_i}(x))^2 < 0$).

Videos del 2023 relacionados: video 4.