

Orden del Tema

1 Introducción

2 Algoritmos Cuasi-Newton

Corrección de rango 1. Symmetric rank 1 (SR1)

Corrección de rango 2. Davidon-Fletcher-Powell (DFP)

Algoritmo DFP usando aproximación del Hessiano

Algoritmo BFGS

Algoritmo L-BFGS

Introducción: Algoritmo de Newton

- El método de Newton es un algoritmo iterativo que permite obtener el óptimo \mathbf{x}^* de una función 2 veces continuamente diferenciable $f : \mathbb{R}^n \rightarrow \mathbb{R}$.
- Es un algoritmo de optimización sin restricciones
- A partir de un punto inicial \mathbf{x}_0 se genera una secuencia $\{\mathbf{x}_k\}$

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\nabla^2 f_k)^{-1} \nabla f_k$$

donde $\nabla^2 f_k = \nabla^2 f(\mathbf{x}_k)$ es el Hessiano y $\nabla f_k = \nabla f(\mathbf{x}_k)$ es el gradiente

Introducción

- Para encontrar el nuevo punto \mathbf{x}_{k+1} a partir de \mathbf{x}_k , se define $\mathbf{d} = \mathbf{x} - \mathbf{x}_k$ y se usa una aproximación de Taylor de segundo orden de la función

$$m_k(\mathbf{d}) = f_k + \nabla^T f_k \mathbf{d} + \frac{1}{2} \mathbf{d}^T \nabla^2 f_k \mathbf{d}$$

- El tamaño de paso p se obtiene calculando el gradiente, igualando a cero y resolviendo para p

$$\nabla f_k + \nabla^2 f_k \mathbf{d} = 0$$

$$\mathbf{d} = -(\nabla^2 f_k)^{-1} \nabla f_k$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k (\nabla^2 f_k)^{-1} \nabla f_k, \quad \alpha_k = 1$$

Introducción

- Para encontrar el nuevo punto \mathbf{x}_{k+1} a partir de \mathbf{x}_k , se define $\mathbf{d} = \mathbf{x} - \mathbf{x}_k$ y se usa una aproximación de Taylor de segundo orden de la función

$$m_k(\mathbf{d}) = f_k + \nabla^T f_k \mathbf{d} + \frac{1}{2} \mathbf{d}^T \nabla^2 f_k \mathbf{d}$$

- El tamaño de paso p se obtiene calculando el gradiente, igualando a cero y resolviendo para p

$$\nabla f_k + \nabla^2 f_k \mathbf{d} = 0$$

$$\mathbf{d} = -(\nabla^2 f_k)^{-1} \nabla f_k$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k (\nabla^2 f_k)^{-1} \nabla f_k, \quad \alpha_k = 1$$

Introducción

- Una de la problemáticas del método de Newton es que requiere calcular el Hessiano $\nabla^2 f_k$ el cual puede ser muy costoso
- Más aún, requiere del cálculo de la inversa del Hessiano

$$d_k = -(\nabla^2 f_k)^{-1} \nabla f_k$$

- Otro problema es que no se puede garantizar que d_k sea una dirección de descenso, i.e, puede suceder que $d_k^T \nabla f_k = -\nabla^T f_k (\nabla^2 f_k)^{-1} \nabla f_k > 0$ en alguna o varias iteraciones ..., por ejemplo, si $\nabla^2 f_k$ es definida negativa.

Introducción

- Una alternativa de solución, cuando d_k no es una dirección de descenso, es modificar el Hessiano añadiendo una matrix \mathbf{E}_k de modo que la nueva matriz $\mathbf{B}_k = \nabla^2 f_k + \mathbf{E}_k$ sea definida positiva. En ejemplo trivial, sería hacer \mathbf{E}_k un múltiplo de la matriz idéntica $\mathbf{E}_k = \tau \mathbf{I}$. La nueva dirección de descenso sería

$$d = -\mathbf{B}_k^{-1} \nabla f_k$$

- La alternativa anterior garantiza que la dirección d_k sea de descenso, sin embargo, requiere del cálculo de Hessiano. Además necesita de un algoritmo que garantice que la nueva matriz \mathbf{B}_k sea definida positiva (p.e. Cholesky).
- Existe alguna otra alternativa??

Introducción

- Una alternativa de solución, cuando d_k no es una dirección de descenso, es modificar el Hessiano añadiendo una matriz \mathbf{E}_k de modo que la nueva matriz $\mathbf{B}_k = \nabla^2 f_k + \mathbf{E}_k$ sea definida positiva. En ejemplo trivial, sería hacer \mathbf{E}_k un múltiplo de la matriz idéntica $\mathbf{E}_k = \tau \mathbf{I}$. La nueva dirección de descenso sería

$$d = -\mathbf{B}_k^{-1} \nabla f_k$$

- La alternativa anterior garantiza que la dirección d_k sea de descenso, sin embargo, requiere del cálculo de Hessiano. Además necesita de un algoritmo que garantice que la nueva matriz \mathbf{B}_k sea definida positiva (p.e. Cholesky).
- Existe alguna otra alternativa??

Introducción

- Una alternativa de solución, cuando d_k no es una dirección de descenso, es modificar el Hessiano añadiendo una matrix \mathbf{E}_k de modo que la nueva matriz $\mathbf{B}_k = \nabla^2 f_k + \mathbf{E}_k$ sea definida positiva. En ejemplo trivial, sería hacer \mathbf{E}_k un múltiplo de la matriz idéntica $\mathbf{E}_k = \tau \mathbf{I}$. La nueva dirección de descenso sería

$$d = -\mathbf{B}_k^{-1} \nabla f_k$$

- La alternativa anterior garantiza que la dirección d_k sea de descenso, sin embargo, requiere del cálculo de Hessiano. Además necesita de un algoritmo que garantice que la nueva matriz \mathbf{B}_k sea definida positiva (p.e. Cholesky).
- **Existe alguna otra alternativa??**

Introducción

- Los métodos cuasi-newton construyen un modelo que se basa en medir los cambios del gradiente.
- Solo requieren del cálculo del gradiente, similar al algoritmo de máximo descenso.
- Su comportamiento es superior al algoritmo de máximo descenso.
- En lugar de calcular el Hessiano en cada iteración se propone un método que permite calcular una secuencia \mathbf{B}_k usando la curvatura medida en el paso actual.

Introducción

- El primer algoritmo Cuasi-Newton fue propuesto por Davidson en 1959, luego fue estudiado por Fletcher and Powell, y es conocido como el *Algoritmo DFP* en honor a sus trabajos.
- Una mejora del algoritmo *DFP* se obtuvo independientemente por Broyden, Fletcher, Goldfarb y Shanno por eso es conocido como el *Algoritmo BFGS*

Orden del Tema

1 Introducción

2 Algoritmos Cuasi-Newton

Corrección de rango 1. Symmetric rank 1 (SR1)

Corrección de rango 2. Davidon-Fletcher-Powell (DFP)

Algoritmo DFP usando aproximación del Hessiano

Algoritmo BFGS

Algoritmo L-BFGS

Recordatorio

En el problema cuadrático

$$\text{mín } f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} - \mathbf{b}^T \mathbf{x}$$

donde $\mathbf{Q}^T = \mathbf{Q}$, al usar la actualización de descenso

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha \mathbf{d}_k$$

Por otro lado

$$\mathbf{g}_{k+1} = \mathbf{Q} \mathbf{x}_{k+1} - \mathbf{b}$$

$$\mathbf{g}_k = \mathbf{Q} \mathbf{x}_k - \mathbf{b}$$

se llega a la conclusión

$$\mathbf{Q}(\mathbf{x}_{k+1} - \mathbf{x}_k) = \mathbf{g}_{k+1} - \mathbf{g}_k$$

Recordatorio

Definiendo $\mathbf{y}_k = \mathbf{g}_{k+1} - \mathbf{g}_k$ y $\mathbf{s}_k = \mathbf{x}_{k+1} - \mathbf{x}_k$ se tiene la relación

$$\mathbf{Q}\mathbf{s}_k = \mathbf{y}_k$$

que se conoce como **ecuación de la secante**. Podemos escribir también

$$\mathbf{Q}^{-1}\mathbf{y}_k = \mathbf{s}_k$$

Idea General

Para el problema general

$$\text{mín } f(\mathbf{x})$$

La idea de los métodos Cuasi-Newton es usar una aproximación del método de Newton

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{B}_k^{-1} \mathbf{g}_k$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_k \mathbf{g}_k$$

donde $\mathbf{B}_k \approx \nabla^2 f_k$ o $\mathbf{H}_k \approx \nabla^2 f_k^{-1}$.

Idea General

Que se obtienen de minimizar alguno de los modelos

$$m_{k+1}(\mathbf{d}) = f_{k+1} + \nabla^T f_{k+1} \mathbf{d} + \frac{1}{2} \mathbf{d}^T \mathbf{B}_{k+1} \mathbf{d}$$

$$m_{k+1}(\mathbf{d}) = f_{k+1} + \nabla^T f_{k+1} \mathbf{d} + \frac{1}{2} \mathbf{d}^T \mathbf{H}_{k+1}^{-1} \mathbf{d}$$

donde $\mathbf{B}_k \approx \nabla^2 f_k$ o $\mathbf{H}_k \approx \nabla^2 f_k^{-1}$.

Idea General

Para determinar las matrices anteriores se imponen algunas condiciones a las matrices \mathbf{B}_{k+1} o \mathbf{H}_{k+1} .

Por ejemplo se pide que sean simétricas y satisfagan la ecuación de la secante, ie

$$\mathbf{B}_{k+1} \mathbf{s}_k = \mathbf{y}_k$$

$$\mathbf{H}_{k+1} \mathbf{y}_k = \mathbf{s}_k$$

Symmetric rank 1

A partir de ahora vamos a aproximar la inversa del Hessiano, ie, $\mathbf{H}_k \approx \nabla^2 f_k^{-1}$.

La idea es construir una secuencia $\mathbf{H}_0, \mathbf{H}_1, \dots$ que satisfaga,

$$\mathbf{H}_{k+1} \mathbf{y}_i = \mathbf{s}_i, i = 0, 1, \dots, k$$

Symmetric rank 1

La corrección de rango 1 se puede escribir como sigue

$$\mathbf{H}_{k+1} = \mathbf{H}_k + \alpha \mathbf{x} \mathbf{x}^T$$

Symmetric rank 1

Luego

$$\begin{aligned}\mathbf{H}_{k+1}\mathbf{y}_k &= \mathbf{H}_k\mathbf{y}_k + \alpha\mathbf{x}\mathbf{x}^T\mathbf{y}_k \\ \alpha\mathbf{x}(\mathbf{x}^T\mathbf{y}_k) &= \mathbf{s}_k - \mathbf{H}_k\mathbf{y}_k \\ \mathbf{x} &= \frac{\mathbf{s}_k - \mathbf{H}_k\mathbf{y}_k}{\alpha\mathbf{x}^T\mathbf{y}_k}\end{aligned}$$

y por tanto

$$\mathbf{H}_{k+1} = \mathbf{H}_k + \frac{(\mathbf{s}_k - \mathbf{H}_k\mathbf{y}_k)(\mathbf{s}_k - \mathbf{H}_k\mathbf{y}_k)^T}{\alpha(\mathbf{x}^T\mathbf{y}_k)^2}$$

cuanto es $\alpha(\mathbf{x}^T\mathbf{y}_k)^2$?

Symmetric rank 1

De la igualdad $\alpha \mathbf{x}(\mathbf{x}^T \mathbf{y}_k) = \mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k$ se tiene

$$\begin{aligned}\alpha \mathbf{x}(\mathbf{x}^T \mathbf{y}_k) &= \mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k \\ \alpha \mathbf{y}_k^T \mathbf{x}(\mathbf{x}^T \mathbf{y}_k) &= \mathbf{y}_k^T (\mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k) \\ \alpha (\mathbf{x}^T \mathbf{y}_k)^2 &= \mathbf{y}_k^T (\mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k)\end{aligned}$$

Por lo que finalmente se tiene

$$\mathbf{H}_{k+1}^{SR1} = \mathbf{H}_k + \frac{(\mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k)(\mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k)^T}{\mathbf{y}_k^T (\mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k)}$$

Orden del Tema

1 Introducción

2 Algoritmos Cuasi-Newton

Corrección de rango 1. Symmetric rank 1 (SR1)

Corrección de rango 2. Davidon-Fletcher-Powell (DFP)

Algoritmo DFP usando aproximación del Hessiano

Algoritmo BFGS

Algoritmo L-BFGS

Symmetric rank 2

La corrección de rango 2 se puede escribir como sigue

$$\mathbf{H}_{k+1} = \mathbf{H}_k + \alpha \mathbf{x} \mathbf{x}^T + \beta \mathbf{y} \mathbf{y}^T$$

satisfaciendo

$$\mathbf{H}_{k+1} \mathbf{y}_k = \mathbf{s}_k$$

Symmetric rank 2

Luego

$$\begin{aligned}\mathbf{H}_{k+1}\mathbf{y}_k &= \mathbf{H}_k\mathbf{y}_k + \alpha\mathbf{x}\mathbf{x}^T\mathbf{y}_k + \beta\mathbf{y}\mathbf{y}^T\mathbf{y}_k \\ \alpha\mathbf{x}(\mathbf{x}^T\mathbf{y}_k) + \beta\mathbf{y}(\mathbf{y}^T\mathbf{y}_k) &= \mathbf{s}_k - \mathbf{H}_k\mathbf{y}_k \\ \alpha(\mathbf{x}^T\mathbf{y}_k)\mathbf{x} + \beta(\mathbf{y}^T\mathbf{y}_k)\mathbf{y} &= \mathbf{s}_k - \mathbf{H}_k\mathbf{y}_k\end{aligned}$$

La ecuación anterior tiene infinitas soluciones, por lo que podemos tomar o podemos definir convenientemente

$$\begin{aligned}\mathbf{x} &= \mathbf{s}_k \\ \mathbf{y} &= \mathbf{H}_k\mathbf{y}_k\end{aligned}$$

Symmetric rank 2

$$[\alpha(\mathbf{x}^T \mathbf{y}_k)] \mathbf{s}_k + [\beta(\mathbf{y}^T \mathbf{y}_k)] \mathbf{H}_k \mathbf{y}_k = \mathbf{s}_k - \mathbf{H}_k \mathbf{y}_k$$

Luego se toma

$$\begin{aligned}\alpha(\mathbf{x}^T \mathbf{y}_k) &= 1 \\ \beta(\mathbf{y}^T \mathbf{y}_k) &= -1\end{aligned}$$

es decir

$$\begin{aligned}\alpha &= \frac{1}{\mathbf{x}^T \mathbf{y}_k} = \frac{1}{\mathbf{s}_k^T \mathbf{y}_k} \\ \beta &= -\frac{1}{\mathbf{y}^T \mathbf{y}_k} = -\frac{1}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k}\end{aligned}$$

Symmetric rank 2

Finalmente se tiene

$$\mathbf{H}_{k+1}^{DFP} = \mathbf{H}_k + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k} - \frac{\mathbf{H}_k \mathbf{y}_k \mathbf{y}_k^T \mathbf{H}_k}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k}$$

Algoritmo DFP: aproximando la inversa del Hessiano

Algorithm 1 DFP

Require: x_0 y H_0

Ensure: x^*

- 1: $k = 0$
- 2: **while** $\|\nabla f_k\| \neq 0$ (No conveja) **do**
- 3: $d_k = -H_k \nabla f_k$
- 4: Calcular α_k usando búsqueda en línea.
- 5: $x_{k+1} = x_k + \alpha_k d_k$
- 6: Calcular ∇f_{k+1} , y_k , s_k y actualizar H_{k+1}

$$H_{k+1} = H_k - \frac{H_k y_k y_k^T H_k}{y_k^T H_k y_k} + \frac{s_k s_k^T}{y_k^T s_k}$$

- 7: $k = k + 1$
 - 8: **end while**
-

Orden del Tema

1 Introducción

2 Algoritmos Cuasi-Newton

Corrección de rango 1. Symmetric rank 1 (SR1)

Corrección de rango 2. Davidon-Fletcher-Powell (DFP)

Algoritmo DFP usando aproximación del Hessiano

Algoritmo BFGS

Algoritmo L-BFGS

DFP usando aproximación del Hessiano

Se tiene

$$\mathbf{H}_{k+1} = \mathbf{H}_k - \frac{\mathbf{H}_k \mathbf{y}_k \mathbf{y}_k^T \mathbf{H}_k}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k} + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k}$$

Definamos \mathbf{U} , \mathbf{V} , a y b y eliminemos los índices por comodidad

$$\begin{aligned}\mathbf{U} &= [a\mathbf{s}, b\mathbf{H}\mathbf{y}] \\ \mathbf{V} &= \begin{bmatrix} a\mathbf{s}^T \\ -b\mathbf{y}^T \mathbf{H} \end{bmatrix} \\ a^2 &= \frac{1}{\mathbf{y}^T \mathbf{s}} \\ b^2 &= \frac{1}{\mathbf{y}^T \mathbf{H} \mathbf{y}}\end{aligned}$$

DFP usando aproximación del Hessiano

Nota que

$$\begin{aligned}\mathbf{UV} &= [\mathbf{as}, \mathbf{bHy}] \begin{bmatrix} \mathbf{as}^T \\ -\mathbf{by}^T \mathbf{H} \end{bmatrix} \\ &= a^2 \mathbf{ss}^T - b^2 \mathbf{Hy} \mathbf{y}^T \mathbf{H} \\ &= \frac{\mathbf{ss}^T}{\mathbf{y}^T \mathbf{s}} - \frac{\mathbf{Hy} \mathbf{y}^T \mathbf{H}}{\mathbf{y}^T \mathbf{Hy}}\end{aligned}$$

DFP usando aproximación del Hessiano

Luego podemos escribir

$$\begin{aligned}\mathbf{H}_{k+1} &= \mathbf{H}_k - \frac{\mathbf{H}_k \mathbf{y}_k \mathbf{y}_k^T \mathbf{H}_k}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k} + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{y}_k^T \mathbf{s}_k} \\ &= \mathbf{H}_k + \mathbf{U}_k \mathbf{V}_k\end{aligned}$$

Aplicamos la formula de Sherman-Morrison-Woodbury

$$(\mathbf{A} + \mathbf{UV})^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1} \mathbf{U} (\mathbf{I} + \mathbf{VA}^{-1} \mathbf{U})^{-1} \mathbf{VA}^{-1}$$

DFP usando aproximación del Hessiano

Como $\mathbf{B} = \mathbf{H}^{-1}$, ie, $\mathbf{B}\mathbf{H} = \mathbf{I}$

$$\begin{aligned}(\mathbf{H} + \mathbf{U}\mathbf{V})^{-1} &= \mathbf{H}^{-1} - \mathbf{H}^{-1}\mathbf{U}(\mathbf{I} + \mathbf{V}\mathbf{H}^{-1}\mathbf{U})^{-1}\mathbf{V}\mathbf{H}^{-1} \\ &= \mathbf{B} - \mathbf{B}\mathbf{U}(\mathbf{I} + \mathbf{V}\mathbf{B}\mathbf{U})^{-1}\mathbf{V}\mathbf{B}\end{aligned}$$

Primero calculemos $\mathbf{V}\mathbf{B}\mathbf{U}$ y luego $(\mathbf{I} + \mathbf{V}\mathbf{B}\mathbf{U})^{-1}$

DFP usando aproximación del Hessiano

$$\begin{aligned} \text{VBU} &= \begin{bmatrix} a\mathbf{s}^T \\ -b\mathbf{y}^T \mathbf{H} \end{bmatrix} \mathbf{B}[a\mathbf{s}, b\mathbf{H}\mathbf{y}] \\ &= \begin{bmatrix} a\mathbf{s}^T \\ -b\mathbf{y}^T \mathbf{H} \end{bmatrix} [a\mathbf{B}\mathbf{s}, b\mathbf{B}\mathbf{H}\mathbf{y}] \\ &= \begin{bmatrix} a^2 \mathbf{s}^T \mathbf{B}\mathbf{s} & ab\mathbf{s}^T \mathbf{B}\mathbf{H}\mathbf{y} \\ -ab\mathbf{y}^T \mathbf{H}\mathbf{B}\mathbf{s} & -b^2 \mathbf{y}^T \mathbf{H}\mathbf{B}\mathbf{H}\mathbf{y} \end{bmatrix} \\ &= \begin{bmatrix} a^2 \mathbf{s}^T \mathbf{B}\mathbf{s} & ab\mathbf{s}^T \mathbf{y} \\ -ab\mathbf{y}^T \mathbf{s} & -b^2 \mathbf{y}^T \mathbf{H}\mathbf{y} \end{bmatrix} \\ &= \begin{bmatrix} a^2 \mathbf{s}^T \mathbf{B}\mathbf{s} & ab\mathbf{s}^T \mathbf{y} \\ -ab\mathbf{y}^T \mathbf{s} & -1 \end{bmatrix} \end{aligned}$$

DFP usando aproximación del Hessiano

$$\begin{aligned}\mathbf{I} + \mathbf{VBU} &= \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} + \begin{bmatrix} a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} & ab \mathbf{s}^T \mathbf{y} \\ -ab \mathbf{y}^T \mathbf{s} & -1 \end{bmatrix} \\ &= \begin{bmatrix} a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1 & ab \mathbf{s}^T \mathbf{y} \\ -ab \mathbf{y}^T \mathbf{s} & 0 \end{bmatrix}\end{aligned}$$

Luego

$$(\mathbf{I} + \mathbf{VBU})^{-1} = \frac{1}{(ab)^2 (\mathbf{y}^T \mathbf{s})^2} \begin{bmatrix} 0 & -ab \mathbf{s}^T \mathbf{y} \\ ab \mathbf{y}^T \mathbf{s} & a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1 \end{bmatrix}$$

DFP usando aproximación del Hessiano

$$\begin{aligned}
 & \mathbf{U}(\mathbf{I} + \mathbf{VBU})^{-1}\mathbf{V} \\
 = & \frac{1}{(ab)^2(\mathbf{y}^T \mathbf{s})^2} [a\mathbf{s}, b\mathbf{Hy}] \begin{bmatrix} 0 & -ab\mathbf{y}^T \mathbf{s} \\ ab\mathbf{y}^T \mathbf{s} & a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1 \end{bmatrix} \begin{bmatrix} a\mathbf{s}^T \\ -b\mathbf{y}^T \mathbf{H} \end{bmatrix} \\
 = & \frac{1}{(ab)^2(\mathbf{y}^T \mathbf{s})^2} [a\mathbf{s}, b\mathbf{Hy}] \begin{bmatrix} ab^2 \mathbf{y}^T \mathbf{s} \mathbf{y}^T \mathbf{H} \\ a^2 b \mathbf{y}^T \mathbf{s} \mathbf{s}^T - b(a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{y}^T \mathbf{H} \end{bmatrix} \\
 = & \frac{a^2 b^2 \mathbf{y}^T \mathbf{s} \mathbf{s} \mathbf{y}^T \mathbf{H} + a^2 b^2 \mathbf{y}^T \mathbf{s} \mathbf{H} \mathbf{y} \mathbf{s}^T - b^2 (a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{H} \mathbf{y} \mathbf{y}^T \mathbf{H}}{a^2 b^2 (\mathbf{y}^T \mathbf{s})^2} \\
 = & \frac{a^2 \mathbf{y}^T \mathbf{s} \mathbf{H} \mathbf{y} \mathbf{s}^T + a^2 \mathbf{y}^T \mathbf{s} \mathbf{s} \mathbf{y}^T \mathbf{H} - (a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{H} \mathbf{y} \mathbf{y}^T \mathbf{H}}{\mathbf{y}^T \mathbf{s}} \\
 = & a^2 \mathbf{H} \mathbf{y} \mathbf{s}^T + a^2 \mathbf{s} \mathbf{y}^T \mathbf{H} - \frac{(a^2 \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{H} \mathbf{y} \mathbf{y}^T \mathbf{H}}{\mathbf{y}^T \mathbf{s}}
 \end{aligned}$$

DFP usando aproximación del Hessiano

Como $\rho = a^2 = \frac{1}{\mathbf{y}^T \mathbf{s}}$ entonces

$$\mathbf{U}(\mathbf{I} + \mathbf{VBU})^{-1}\mathbf{V} = \rho \mathbf{H} \mathbf{y} \mathbf{s}^T + \rho \mathbf{s} \mathbf{y}^T \mathbf{H} - \rho(\rho \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{H} \mathbf{y} \mathbf{y}^T \mathbf{H}$$

Luego

$$\begin{aligned} & \mathbf{BU}(\mathbf{I} + \mathbf{VBU})^{-1}\mathbf{VB} \\ &= \rho \mathbf{B} \mathbf{H} \mathbf{y} \mathbf{s}^T \mathbf{B} + \rho \mathbf{B} \mathbf{s} \mathbf{y}^T \mathbf{H} \mathbf{B} - \rho(\rho \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{B} \mathbf{H} \mathbf{y} \mathbf{y}^T \mathbf{H} \mathbf{B} \\ &= \rho \mathbf{y} \mathbf{s}^T \mathbf{B} + \rho \mathbf{B} \mathbf{s} \mathbf{y}^T - \rho(\rho \mathbf{s}^T \mathbf{B} \mathbf{s} + 1) \mathbf{y} \mathbf{y}^T \end{aligned}$$

DFP usando aproximación del Hessiano

$$\begin{aligned} & (\mathbf{H} + \mathbf{UV})^{-1} \\ &= \mathbf{B} - \mathbf{BU}(\mathbf{I} + \mathbf{VBU})^{-1}\mathbf{VB} \\ &= \mathbf{B} - \rho\mathbf{y}\mathbf{s}^T\mathbf{B} - \rho\mathbf{B}\mathbf{s}\mathbf{y}^T + \rho^2\mathbf{s}^T\mathbf{B}\mathbf{s}\mathbf{y}\mathbf{y}^T + \rho\mathbf{y}\mathbf{y}^T \\ &= \mathbf{B} - \rho\mathbf{y}\mathbf{s}^T\mathbf{B} - \rho\mathbf{B}\mathbf{s}\mathbf{y}^T + \rho^2\mathbf{y}\mathbf{s}^T\mathbf{B}\mathbf{s}\mathbf{y}^T + \rho\mathbf{y}\mathbf{y}^T \\ &= (\mathbf{I} - \rho\mathbf{y}\mathbf{s}^T)\mathbf{B} - (\mathbf{I} - \rho\mathbf{y}\mathbf{s}^T)\rho\mathbf{B}\mathbf{s}\mathbf{y}^T + \rho\mathbf{y}\mathbf{y}^T \\ &= (\mathbf{I} - \rho\mathbf{y}\mathbf{s}^T)\mathbf{B} - (\mathbf{I} - \rho\mathbf{y}\mathbf{s}^T)\rho\mathbf{B}\mathbf{s}\mathbf{y}^T + \rho\mathbf{y}\mathbf{y}^T \\ &= (\mathbf{I} - \rho\mathbf{y}\mathbf{s}^T)(\mathbf{B} - \rho\mathbf{B}\mathbf{s}\mathbf{y}^T) + \rho\mathbf{y}\mathbf{y}^T \\ &= (\mathbf{I} - \rho\mathbf{y}\mathbf{s}^T)\mathbf{B}(\mathbf{I} - \rho\mathbf{s}\mathbf{y}^T) + \rho\mathbf{y}\mathbf{y}^T \end{aligned}$$

DFP usando aproximación del Hessiano

Finalmente, incluyendo los subíndices

$$\mathbf{B}_{k+1} = (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) \mathbf{B}_k (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) + \rho_k \mathbf{y}_k \mathbf{y}_k^T$$

$$\text{con } \rho_k = \frac{1}{\mathbf{y}_k^T \mathbf{s}_k}$$

Note que $\mathbf{B}_{k+1} \succ 0$ siempre que $\mathbf{B}_k \succ 0$, $\rho_k > 0$ y no se halla llegado a la solución, esto último significa que $\mathbf{y}_k \neq 0$. Para ello, se puede verificar que $\mathbf{x}^T \mathbf{B}_{k+1} \mathbf{x} > 0$ para todo $\mathbf{x} \neq 0$. Una idea es considerar los casos $\mathbf{x}^T \mathbf{y}_k = 0$ y $\mathbf{x}^T \mathbf{y}_k \neq 0$

DFP usando aproximación del Hessiano

En resumen, para Davidon-Fletcher-Powell (DFP) se cumple

$$\mathbf{H}_{k+1}^{DFP} = \mathbf{H}_k - \frac{\mathbf{H}_k \mathbf{y}_k \mathbf{y}_k^T \mathbf{H}_k}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k} + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{y}_k^T \mathbf{s}_k}$$

Usando la formula de Sherman-Morrison-Woodbury

$$\mathbf{B}_{k+1}^{DFP} = (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) \mathbf{B}_k (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) + \rho_k \mathbf{y}_k \mathbf{y}_k^T$$

DFP- aproximando el Hessiano

Algorithm 2 DFP- aproximando el Hessiano

Require: \mathbf{x}_0 y \mathbf{B}_0

Ensure: \mathbf{x}^*

1: $k = 0$

2: **while** $\|\nabla f_k\| \neq 0$ (No conveja) **do**

3: $\mathbf{d}_k = -\mathbf{B}_k^{-1} \nabla f_k$

4: Calcular α_k usando búsqueda en línea.

5: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$

6: Calcular ∇f_{k+1} , \mathbf{y}_k , \mathbf{s}_k , ρ_k y actualizar \mathbf{B}_{k+1}

$$\mathbf{B}_{k+1} = (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) \mathbf{B}_k (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) + \rho_k \mathbf{y}_k \mathbf{y}_k^T$$

7: $k = k + 1$

8: **end while**

Algoritmo DFP

Algorithm 3 DFP- aproximando la inversa del Hessiano

Require: x_0 y H_0

Ensure: x^*

1: $k = 0$

2: **while** $\|\nabla f_k\| \neq 0$ (No conveja) **do**

3: $d_k = -H_k \nabla f_k$

4: Calcular α_k usando búsqueda en línea.

5: $x_{k+1} = x_k + \alpha_k d_k$

6: Calcular ∇f_{k+1} , y_k , s_k y actualizar H_{k+1}

$$H_{k+1} = H_k - \frac{H_k y_k y_k^T H_k}{y_k^T H_k y_k} + \frac{s_k s_k^T}{y_k^T s_k}$$

7: $k = k + 1$

8: **end while**

Orden del Tema

1 Introducción

2 Algoritmos Cuasi-Newton

Corrección de rango 1. Symmetric rank 1 (SR1)

Corrección de rango 2. Davidon-Fletcher-Powell (DFP)

Algoritmo DFP usando aproximación del Hessiano

Algoritmo BFGS

Algoritmo L-BFGS

Algoritmo BFGS

- En el BFGS la idea es calcular la aproximación de matriz inversa del Hessiano \mathbf{H}_{k+1} basado en \mathbf{B}_{k+1}
- Para ello se considera la ecuación DFP, con $\rho_k = \frac{1}{\mathbf{s}_k^T \mathbf{y}_k}$

$$\mathbf{B}_{k+1} = (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) \mathbf{B}_k (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) + \rho_k \mathbf{y}_k \mathbf{y}_k^T$$

y las relaciones

$$\begin{array}{ccc} \mathbf{B}_{k+1} \mathbf{s}_k & = & \mathbf{y}_k \\ \updownarrow & & \updownarrow \\ \mathbf{H}_{k+1} \mathbf{y}_k & = & \mathbf{s}_k \end{array}$$

Ahora $\rho_k = \frac{1}{\mathbf{y}_k^T \mathbf{s}_k}$ y por tanto:

$$\mathbf{H}_{k+1} = (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) \mathbf{H}_k (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) + \rho_k \mathbf{s}_k \mathbf{s}_k^T$$

Algoritmo BFGS

Algorithm 4 Algoritmo BFGS

Require: \mathbf{x}_0 y \mathbf{H}_0

Ensure: \mathbf{x}^*

1: $k = 0$

2: **while** $\|\nabla f_k\| \neq 0$ (No conveja) **do**

3: $\mathbf{d}_k = -\mathbf{H}_k \nabla f_k$

4: Calcular α_k usando búsqueda en línea.

5: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$

6: Calcular ∇f_{k+1} , \mathbf{y}_k , \mathbf{s}_k , ρ_k y actualizar \mathbf{H}_{k+1}

$$\mathbf{H}_{k+1} = (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) \mathbf{H}_k (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) + \rho_k \mathbf{s}_k \mathbf{s}_k^T$$

7: $k = k + 1$

8: **end while**

BFGS aproximación del Hessiano

$$\mathbf{H}_{k+1}^{DFP} = \mathbf{H}_k - \frac{\mathbf{H}_k \mathbf{y}_k \mathbf{y}_k^T \mathbf{H}_k}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k} + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{y}_k^T \mathbf{s}_k}$$
$$\mathbf{B}_{k+1}^{BFGS} = \mathbf{B}_k - \frac{\mathbf{B}_k \mathbf{s}_k \mathbf{s}_k^T \mathbf{B}_k}{\mathbf{s}_k^T \mathbf{B}_k \mathbf{s}_k} + \frac{\mathbf{y}_k \mathbf{y}_k^T}{\mathbf{s}_k^T \mathbf{y}_k}$$

DFP vs BFGS

En resumen

$$\mathbf{H}_{k+1}^{DFP} = \mathbf{H}_k - \frac{\mathbf{H}_k \mathbf{y}_k \mathbf{y}_k^T \mathbf{H}_k}{\mathbf{y}_k^T \mathbf{H}_k \mathbf{y}_k} + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{y}_k^T \mathbf{s}_k}$$
$$\mathbf{B}_{k+1}^{BFGS} = \mathbf{B}_k - \frac{\mathbf{B}_k \mathbf{s}_k \mathbf{s}_k^T \mathbf{B}_k}{\mathbf{s}_k^T \mathbf{B}_k \mathbf{s}_k} + \frac{\mathbf{y}_k \mathbf{y}_k^T}{\mathbf{s}_k^T \mathbf{y}_k}$$

$$\mathbf{B}_{k+1}^{DFP} = (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) \mathbf{B}_k (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) + \rho_k \mathbf{y}_k \mathbf{y}_k^T$$
$$\mathbf{H}_{k+1}^{BFGS} = (\mathbf{I} - \rho_k \mathbf{s}_k \mathbf{y}_k^T) \mathbf{H}_k (\mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T) + \rho_k \mathbf{s}_k \mathbf{s}_k^T$$

Si el tamaño de paso cumple las condiciones de Wolfe con $0 < c_2 < 1$, y si $\nabla f_k \neq 0$, entonces

$$\begin{aligned} \nabla f_{k+1}^T \mathbf{d}_k &\geq c_2 \nabla f_k^T \mathbf{d}_k \\ \nabla f_{k+1}^T \alpha_k \mathbf{d}_k &\geq c_2 \nabla f_k^T \alpha_k \mathbf{d}_k \\ \mathbf{g}_{k+1}^T \mathbf{s}_k &\geq c_2 \mathbf{g}_k^T \mathbf{s}_k \\ \mathbf{g}_{k+1}^T \mathbf{s}_k - \mathbf{g}_k^T \mathbf{s}_k &\geq c_2 \mathbf{g}_k^T \mathbf{s}_k - \mathbf{g}_k^T \mathbf{s}_k \\ \mathbf{y}_k^T \mathbf{s}_k &\geq (c_2 - 1) \mathbf{g}_k^T \mathbf{s}_k \\ \mathbf{y}_k^T \mathbf{s}_k &\geq \underbrace{(c_2 - 1)}_{<0} \overbrace{\alpha_k}^{>0} \underbrace{\mathbf{g}_k^T \mathbf{d}_k}_{<0} \end{aligned}$$

Luego

$$\mathbf{y}_k^T \mathbf{s}_k \geq (c_2 - 1) \alpha_k \mathbf{g}_k^T \mathbf{d}_k > 0$$

por tanto $\rho_k > 0$ y \mathbf{H}_{k+1} es definida positiva.

Orden del Tema

1 Introducción

2 Algoritmos Cuasi-Newton

Corrección de rango 1. Symmetric rank 1 (SR1)

Corrección de rango 2. Davidon-Fletcher-Powell (DFP)

Algoritmo DFP usando aproximación del Hessiano

Algoritmo BFGS

Algoritmo L-BFGS

Algoritmo L-BFGS

- El algoritmo BFGS es presenta un buen desempeño y no requiere el cálculo del Hessiano ni de su inversa.
- La principal limitación del algoritmo BFGS es en problemas donde el número de variable es muy grande (por ejemplo, un millón de variables o mas) pues es casi imposible guardar la matriz de tamaño $n \times n$.
- Una solución a problemas de *gran escala* es el algoritmo **L-BFGS** ('Limited memory BFGS').

Algoritmo L-BFGS

- **Observación 1:** La matriz

$$\mathbf{H}_k = (\mathbf{I} - \rho_{k-1} \mathbf{s}_{k-1} \mathbf{y}_{k-1}^T) \mathbf{H}_{k-1} (\mathbf{I} - \rho_{k-1} \mathbf{y}_{k-1} \mathbf{s}_{k-1}^T) + \rho_{k-1} \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T$$

se actualiza usando matrices de rango 1, i.e.,

$$\begin{aligned} & \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T, \\ \mathbf{V}_{k-1} &= \mathbf{I} - \rho_{k-1} \mathbf{y}_{k-1} \mathbf{s}_{k-1}^T, \\ \mathbf{V}_{k-1}^T &= \mathbf{I} - \rho_{k-1} \mathbf{s}_{k-1} \mathbf{y}_{k-1}^T. \end{aligned}$$

Algoritmo L-BFGS

- **Observación 2:** Para resolver el problema de optimización, lo que se requiere es calcular el paso $\mathbf{d}_k = -\mathbf{H}_k \nabla f_k$
- Es decir, en la práctica no es interés conocer \mathbf{H}_k sino el producto $\mathbf{H}_k \nabla f_k$
- **Observación 3:** De

$$\mathbf{H}_k \nabla f_k = \mathbf{V}_{k-1}^T \mathbf{H}_{k-1} \mathbf{V}_{k-1} \nabla f_k + \rho_{k-1} \mathbf{s}_{k-1} (\mathbf{s}_{k-1}^T \nabla f_k)$$

donde $\mathbf{V}_{k-1} \nabla f_k = \nabla f_k - \rho_{k-1} \mathbf{y}_{k-1} (\mathbf{s}_{k-1}^T \nabla f_k)$ y $\rho_{k-1} \mathbf{s}_{k-1} (\mathbf{s}_{k-1}^T \nabla f_k)$ son vectores, y las operaciones son sumas y productos interiores.

Algoritmo L-BFGS

- La ecuación del Hessiano se puede reescribir, sustituyendo \mathbf{H}_{k-1} por su ecuación en función de \mathbf{H}_{k-2}

$$\mathbf{H}_k = (\mathbf{V}_{k-1}^T \mathbf{V}_{k-2}^T) \mathbf{H}_{k-2} (\mathbf{V}_{k-1} \mathbf{V}_{k-2}) + \mathbf{V}_{k-1}^T \mathbf{s}_{k-2} \rho_{k-2} \mathbf{s}_{k-2}^T \mathbf{V}_{k-1} + \mathbf{s}_{k-1} \rho_{k-1} \mathbf{s}_{k-1}^T$$

- En azul y rojo son vectores o matrices donde el cálculo solo involucra productos interiores.
- En verde aparece la matriz \mathbf{H}_{k-2} y otras operaciones matriciales.

Algoritmo L-BFGS

- Al multiplicar por ∇f_k

$$\begin{aligned}\mathbf{H}_k \nabla f_k &= (\mathbf{V}_{k-1}^T \mathbf{V}_{k-2}^T) \mathbf{H}_{k-2} (\mathbf{V}_{k-1} \mathbf{V}_{k-2}) \nabla f_k \\ &+ \mathbf{V}_{k-1}^T \mathbf{s}_{k-2} \rho_{k-2} \mathbf{s}_{k-2}^T \mathbf{V}_{k-1} \nabla f_k \\ &+ \mathbf{s}_{k-1} \rho_{k-1} \mathbf{s}_{k-1}^T \nabla f_k\end{aligned}$$

- En azul son vectores, y su cálculo solo involucra productos interiores.
- En rojo el producto resultante es un número real y su cálculo solo involucra productos interiores.
- En verde aparece la matriz \mathbf{H}_{k-2} y otras operaciones matriciales.

Algoritmo L-BFGS

- Continuado el proceso

$$\begin{aligned}
 \mathbf{H}_k = & \\
 & (\mathbf{V}_{-1}^T \mathbf{V}_{-2}^T \cdots \mathbf{V}_{-m}^T) \mathbf{H}_{-m}^0 (\mathbf{V}_{-1} \mathbf{V}_{-2} \cdots \mathbf{V}_{-m}) \\
 & + (\mathbf{V}_{-1}^T \mathbf{V}_{-2}^T \cdots \mathbf{V}_{-m+1}^T) \mathbf{s}_{-m} \rho_{-m} \mathbf{s}_{-m}^T (\mathbf{V}_{-1} \mathbf{V}_{-2} \cdots \mathbf{V}_{-m+1}) \\
 & + (\mathbf{V}_{-1}^T \mathbf{V}_{-2}^T \cdots \mathbf{V}_{-m+2}^T) \mathbf{s}_{-m+1} \rho_{-m+1} \mathbf{s}_{-m+1}^T (\mathbf{V}_{-1} \mathbf{V}_{-2} \cdots \mathbf{V}_{-m+2}) \\
 & \dots \\
 & + \mathbf{V}_{-1}^T \mathbf{s}_{-2} \rho_{-2} \mathbf{s}_{-2}^T \mathbf{V}_{-1} \\
 & + \mathbf{s}_{-1} \rho_{-1} \mathbf{s}_{-1}^T
 \end{aligned}$$

Nota: para el índice $k - i$ se usa $-i$ y $\mathbf{H}_{-m}^0 = \mathbf{H}_{k-m}$

Algoritmo L-BFGS

- \mathbf{H}_{-m}^0 juega el papel de \mathbf{H}_0 en el BFGS y es como si en lugar de iniciar en \mathbf{x}_0 hubiéramos iniciado en \mathbf{x}_{-m} .
- En problema en el algoritmo anterior es que se requiere calcular $\mathbf{H}_{-m}^0 \mathbf{q}$, y no queremos guardar \mathbf{H}_{-m}^0 .
- Para ello se toma \mathbf{H}_{-m}^0 usando una forma simple, por ejemplo, un múltiplo de la matriz identidad.
- En la práctica $\mathbf{H}_{-m}^0 = \gamma_k \mathbf{I}$ con $\gamma_k = \frac{\mathbf{s}_{k-1}^T \mathbf{y}_{k-1}}{\mathbf{y}_{k-1}^T \mathbf{y}_{k-1}}$ ha mostrado buenos resultados.

Algoritmo L-BFGS

- El cálculo de $\mathbf{H}_k \nabla f_k$ se puede realizar guardando, por ejemplo, m pareja de vectores $\{s_i, y_i\}$ anteriores
- El cálculo se realiza a través de productos interiores y sumas.
- Para la siguiente iteración se guarda la última pareja $\{s_k, y_k\}$ y se remueve la primera.
- Notar que se gana en cuanto a memoria, sin embargo, aumenta el tiempo de cómputo!!!.

Algoritmo L-BFGS

Algorithm 5 Algoritmo para calcular el paso L-BFGS

Require: ∇f_k , \mathbf{s}_{-i} , \mathbf{y}_{-i} para $i = 1, \dots, m$

Ensure: \mathbf{r}

- 1: $\mathbf{q} = \nabla f_k$
 - 2: **for** ($i = 1 \dots m$) **do**
 - 3: $\alpha_i = \rho_{-i} \mathbf{s}_{-i}^T \mathbf{q}$
 - 4: $\mathbf{q} = \mathbf{q} - \alpha_i \mathbf{y}_{-i}$
 - 5: **end for**
 - 6: $\mathbf{r} = \mathbf{H}_{-m}^0 \mathbf{q}$
 - 7: **for** ($i = m \dots 1$) **do**
 - 8: $\beta = \rho_{-i} \mathbf{y}_{-i}^T \mathbf{r}$
 - 9: $\mathbf{r} = \mathbf{r} + \mathbf{s}_{-i} (\alpha_i - \beta)$
 - 10: **end for**
-

Algoritmo L-BFGS

Por qué trabaja?

- Sea \mathbf{q}_i el valor de \mathbf{q} después de la i -ésima iteración del primer ciclo y $\mathbf{q}_0 = \nabla f_k$. De acuerdo al algoritmo

$$\begin{aligned}\mathbf{q}_i &= \mathbf{q}_{i-1} - \rho_{-i} \mathbf{y}_{-i} \mathbf{s}_{-i}^T \mathbf{q}_{i-1} = \mathbf{V}_{-i} \mathbf{q}_{i-1} = (\mathbf{V}_{-i} \mathbf{V}_{-i+1}) \mathbf{q}_{i-2} \\ &= \dots = (\mathbf{V}_{-i} \dots \mathbf{V}_{-1}) \nabla f_k\end{aligned}$$

Luego

$$\alpha_i = \rho_{-i} \mathbf{s}_{-i}^T \mathbf{q}_{i-1} = \dots = \rho_{-i} \mathbf{s}_{-i}^T (\mathbf{V}_{-i+1} \dots \mathbf{V}_{-1}) \nabla f_k$$

Algoritmo L-BFGS

Por qué trabaja?

- Calculando \mathbf{r} .

$$\mathbf{r}_m = \mathbf{H}_{-m} \mathbf{q}_m = \mathbf{H}_{-m} (\mathbf{V}_{-m} \cdots \mathbf{V}_{-1}) \nabla f_k$$

- Por otro lado

$$\begin{aligned} \mathbf{r}_i &= \mathbf{r}_{i+1} + \mathbf{s}_{-i} (\alpha_i - \rho_{-i} \mathbf{y}_{-i}^T \mathbf{r}_{i+1}) \\ &= (\mathbf{I} - \mathbf{s}_{-i} \rho_{-i} \mathbf{y}_{-i}^T) \mathbf{r}_{i+1} + \mathbf{s}_{-i} \alpha_i \\ &= \mathbf{V}_{-i}^T \mathbf{r}_{i+1} + \mathbf{s}_{-i} \alpha_i \end{aligned}$$

Algoritmo L-BFGS

Por qué trabaja?

- Comenzando por \mathbf{r}_1 y usando la recursividad anterior y la formula para α_i

$$\begin{aligned}
 \mathbf{r}_1 &= \mathbf{V}_{-1}^T \mathbf{r}_2 + \mathbf{s}_{-1} \rho_{-1} \mathbf{s}_{-1}^T \nabla f_k \\
 &= (\mathbf{V}_{-1}^T \mathbf{V}_{-2}^T) \mathbf{r}_3 + \mathbf{V}_{-1}^T \mathbf{s}_{-2} \rho_{-2} \mathbf{s}_{-2}^T \mathbf{V}_{-1} \nabla f_k + \mathbf{s}_{-1} \rho_{-1} \mathbf{s}_{-1}^T \nabla f_k \\
 &= \dots \\
 &= (\mathbf{V}_{-1}^T \mathbf{V}_{-2}^T \dots \mathbf{V}_{-m}^T) \mathbf{H}_{-m}^0 (\mathbf{V}_{-1} \mathbf{V}_{-2} \dots \mathbf{V}_{-m}) \nabla f_k \\
 &\quad + \dots + \\
 &\quad + \mathbf{V}_{-1}^T \mathbf{s}_{-2} \rho_{-2} \mathbf{s}_{-2}^T \mathbf{V}_{-1} \nabla f_k \\
 &\quad + \mathbf{s}_{-1} \rho_{-1} \mathbf{s}_{-1}^T \nabla f_k \\
 &= \mathbf{H}_k \nabla f_k
 \end{aligned}$$

Algoritmo L-BFGS

Algorithm 6 Algoritmo L-BFGS

- 1: **for** ($i = 1, 2, \dots$) **do**
 - 2: Seleccionar \mathbf{H}_{-m}^0
 - 3: Calcular $\mathbf{d}_k = -\mathbf{H}_k \nabla f_k$, usando el algoritmo anterior de ‘Limited Memory’
 - 4: Calcular α_k usando búsqueda en línea.
 - 5: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$
 - 6: **if** $k > m$ **then**
 - 7: Eliminar la primera pareja $\{\mathbf{s}_{k-m}, \mathbf{y}_{k-m}\}$
 - 8: **end if**
 - 9: Calcular y Guardar $\{\mathbf{s}_k = \mathbf{x}_{k+1} - \mathbf{x}_k, \mathbf{y}_k = \nabla f_{k+1} - \nabla f_k\}$
 - 10: **end for**
-