

### 5.5.1 Globalización por búsqueda lineal

En los métodos con búsqueda lineal los iterantes se generan, en el caso más simple, por la recurrencia siguiente:

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

donde  $d_k$  es una dirección de  $\mathbb{R}^n$  y  $\alpha_k$  es un paso determinado de manera que decrezca una función de mérito.

Vamos a considerar un problema cuadrático mas general que  $(PQT)$  de manera que incluya las versiones cuasi-newtonianas de la programación secuencial cuadrática: el hessiano del lagrangiano se reemplaza por una matriz  $B_k$ . El problema cuadrático en  $d$  se transforma en:

$$\begin{cases} \min \nabla f(x_k)^t d + \frac{1}{2} d^t B_k d \\ c_I(x_k) + A_I(x_k) d = 0 \\ c_D(x_k) + A_D(x_k) d \leq 0, \end{cases} \quad (8)$$

Se supondrá que  $d_k$  verifica las condiciones de optimalidad de de primer orden que se escriben para un multiplicador  $\lambda_k^{PQ}$ :

$$\begin{aligned} B_k d_k + A(x_k)^t \lambda_k^{PQ} &= -\nabla f(x_k) \\ c_I(x_k) + A_I(x_k) d_k &= 0 \\ c_D(x_k) + A_D(x_k) d_k &\leq 0 \\ (\lambda_k^{PQ})_D &\geq 0 \\ (\lambda_k^{PQ})_D^t (c_D(x_k) + A_D(x_k)) &= 0 \end{aligned}$$

La determinación del paso  $\alpha_k$  es compleja y es todavía objeto de investigación. El principio es el siguiente: Se busca  $\alpha_k$  de manera que  $x_{k+1}$  haga decrecer una función de mérito del problema. Por ejemplo se puede tomar:

$$\theta_\sigma = f(x) + \sigma \|c(x)^\#\|$$

y buscar que se cumpla al menos:

$$\theta_\sigma(x_{k+1}) < \theta_\sigma(x_k)$$

Como se verá es necesario ser más exigente que eso. Por otra parte habría que precisar la evolución de las variables  $\lambda_k$ . Ciertos autores hacen una búsqueda lineal en  $\lambda$  utilizando una función de mérito primal-dual. Otros autores proponen simplemente:

$$\lambda_{k+1} = \lambda_k + \alpha_k (\lambda_k^{PQ} - \lambda_k)$$

Para que  $\theta_\sigma$  pueda ser utilizada como función de mérito midiendo el progreso alcanzado desplazándose a lo largo de  $d_k$ , es necesario que  $d_k$  sea una dirección de descenso de  $\theta_\sigma$  en  $x_k$ :

$$\theta'_\sigma(x_k, d_k) < 0$$

Si  $B_k$  es definida positiva y se ajusta  $\sigma_k$  de manera que en cada iteración:

$$\sigma_k \geq \|\lambda_k^{PQ}\|$$

entonces  $d_k$ , solución estacionaria del problema cuadrático, es una dirección de descenso de  $\theta_{\sigma_k}$  en  $x_k$ . Como asintóticamente se debe tener  $\sigma > \|\lambda^*\|$  para que  $\theta_\sigma$  sea una función de penalización exacta, los algoritmos mantienen la desigualdad anterior en cada iteración mediante reglas adecuadas. Para una constante  $\bar{\sigma} > 0$  se adaptará el factor de penalización de manera que:

- $\sigma_k \geq \|\lambda_{PQ}^k\| + \bar{\sigma}$
- existe un índice  $k_1$  tal que  $\forall k \geq k_1$

$$\sigma_{k-1} \geq \|\lambda_{PQ}^k\| + \bar{\sigma} \Rightarrow \sigma_k = \sigma_{k-1}$$

- $\{\sigma_k\}$  acotada  $\Rightarrow \sigma_k$  se modifica un número finito de veces

Vamos a especificar ahora una desigualdad forzando el decrecimiento de  $\theta_{\sigma_k}$ . Elegiremos la *condición de Armijo* siguiente: encontrar  $\alpha > 0$  tal que para  $\omega \in (0, 0.5)$  se cumpla:

$$x_k + \alpha d_k \in \Omega \quad \text{y} \quad \theta_{\sigma_k}(x_k + \alpha d_k) \leq \theta_{\sigma_k}(x_k) + \omega \alpha \Delta_k$$

La exigencia  $\omega < \frac{1}{2}$  se deduce de razones teóricas. El valor de  $\Delta_k$  debería ser idealmente  $\theta'_\sigma(x_k, d_k)$  pero como esta derivada direccional no se puede calcular fácilmente se elige el mayorante:

$$\Delta_k := \nabla f(x_k)^t d_k - \sigma \|c(x_k)^\#\| = -d_k^t B_k d_k - (\lambda_k^{PQ})^t - \sigma \|c(x_k)^\#\|$$

que cumple  $\theta'_\sigma(x_k, d_k) \leq \Delta_k < 0$ .

### 5.5.2 Programación secuencial cuadrática cuasi-newtoniana

Recordemos que, localmente, la programación cuadrática sucesiva calcula un desplazamiento  $d_k$  en  $x$  resolviendo el problema cuadrático en  $d$  siguiente:

$$\begin{cases} \min \nabla f(x_k)^t d + \frac{1}{2} d^t \nabla_{xx}^2 \ell(x_k, \lambda_k) d \\ c_I(x_k) + A_I(x_k) d = 0 \\ c_D(x_k) + A_D(x_k) d \leq 0 \end{cases} \quad (9)$$

En la versión cuasi-newtoniana del algoritmo,  $B_k$  es una matriz simétrica definida positiva, puesta al día por la fórmula BFGS utilizando dos vectores  $\gamma_k$  y  $\delta_k$  a determinar en  $\mathbb{R}^n$ . Parece razonable que  $B_k$  aproxime el hessiano del lagrangiano; por tanto, se puede elegir  $\gamma_k = \gamma_k^\ell$  (variación del gradiente del lagrangiano cuando  $x$  varía), y tomar, para  $\delta_k$  el desplazamiento en  $x$ :

$$\gamma_k^\ell = \nabla \ell(x_{k+1}, \lambda_k^{PQ}) - \nabla \ell(x_k, \lambda_k^{PQ})$$

En  $\gamma_k^\ell$  se ha fijado el multiplicador al valor  $\lambda_k^{PQ}$ , que es más próximo a  $\lambda^*$  que  $\lambda_k$ .

Sería necesario poder realizar la condición  $(\gamma_k^\ell)^t \delta_k > 0$  (que asegura la conservación del carácter definido positivo de  $B_k$ ), eligiendo bien  $x_{k+1}$ .

Es natural elegir  $x_{k+1}$  a lo largo de  $d_k$  haciendo una búsqueda lineal para hacer decrecer una función de mérito. Sin embargo, es posible que el lagrangiano tenga una curvatura negativa sobre  $\{x_k + \alpha d_k \mid \alpha \in \mathbb{R}\}$ , es decir, puede ocurrir que  $(\gamma_k^\ell)^t \delta_k \leq 0$  con  $x_{k+1} = x_k + \alpha_k d_k$  sea cual sea  $\alpha_k > 0$ .

Para resolver esta dificultad Powell propone calcular  $\gamma_k$  modificando  $\gamma_k^\ell$  cuando el producto  $(\gamma_k^\ell)^t \delta_k$  no sea suficientemente positivo. En primer lugar se determina un paso  $\alpha_k$  a lo largo de  $d_k$  de manera que se haga decrecer una función de mérito (por ejemplo la función de penalización de Han) lo que da el iterante siguiente  $x_{k+1} = x_k + \alpha_k d_k$ . Se definen después  $\gamma_k^\ell$  y  $\delta_k$  como antes y se elige  $\gamma_k$  como una combinación convexa de  $\gamma_k^\ell$  y  $B_k \delta_k$ :

$$\gamma_k = \theta \gamma_k^\ell + (1 - \theta) B_k \delta_k$$

donde:

$$\theta = \begin{cases} 1 & \text{si } (\gamma_k^\ell)^t \delta_k \geq 0.2 \delta_k^t B_k \delta_k \\ 0.8 \frac{\delta_k^t B_k \delta_k}{\delta_k^t B_k \delta_k - (\gamma_k^\ell)^t \delta_k} & \text{en otro caso} \end{cases}$$

Para modificar  $\gamma_k^\ell$  lo menos posible (y retener por tanto la mayor información del problema) se elige el parámetro  $\theta$  tan grande como se pueda en  $[0, 1]$  asegurándose de que se cumpla:

$$(\gamma_k)^\ell)^t \delta_k \geq 0.2 \delta_k^t B_k \delta_k$$

Por último se actualiza  $B_k$  con la fórmula BFGS utilizando  $\gamma_k$ . Esta técnica se conoce con el nombre de corrección de Powell.

Se puede dar un algoritmo que resuma todo esto:

### DESCRIPCIÓN DE UNA ITERACIÓN DEL ALGORITMO

Al comienzo de la iteración se conoce el iterante  $(x_k, \lambda_k)$  y una matriz  $B_k$ , simétrica definida positiva, aproximación del hessiano del lagrangiano. La finalidad de la iteración es dar un nuevo valor a estas tres variables.

1. Calcular la única solución primal-dual  $(d_k, \lambda_k^{PQ})$  del problema cuadrático tangente:

$$\begin{cases} \min \nabla f(x^k)d + \frac{1}{2}d^t B_k d \\ c_E(x^k) + A_E(x^k)d = 0 \\ c_I(x^k) + A_I(x^k)d \leq 0, \end{cases} \quad (10)$$

2. Preparación de la búsqueda lineal: adaptar el factor de penalización  $\sigma_k$  de manera que se tenga:

$$\sigma_k \geq \|\lambda_{PQ}^k\| + \bar{\sigma}, \quad (11)$$

donde  $\bar{\sigma} > 0$  es una constante “pequeña”. Las reglas de actualización serán:

Primera iteración:

Se elige

$$\bar{\sigma} = \max(\sqrt{\text{eps}}, \|\lambda_1\|/100) \quad \text{y} \quad \sigma_1 = \|\lambda_1\| + \bar{\sigma},$$

para **eps** igual al valor del  $\epsilon$  del ordenador.

Iteraciones siguientes:

Podemos aumentar el valor de  $\sigma$  para satisfacer (11), pero puede ocurrir que sea muy “grande” para hacer la búsqueda lineal. Entonces hacemos:

$$\begin{aligned} \text{si } \sigma_{k-1} < \|\lambda_k^{PQ}\| + \bar{\sigma}, \\ \quad \sigma_k &= \max(1.5 \sigma_{k-1}, \|\lambda_k^{PQ}\| + \bar{\sigma}); \\ \text{si no, si } \sigma_{k-1} > 1.1 (\|\lambda_k^{PQ}\| + \bar{\sigma}), \\ \quad \sigma_k &= (\sigma_{k-1} + \|\lambda_k^{PQ}\| + \bar{\sigma})/2; \\ \text{si no} \\ \quad \sigma_k &= \sigma_{k-1}. \end{aligned}$$

3. Búsqueda lineal: encontrar un paso  $\alpha_k$  de manera que se verifique la condición de Armijo sobre la función de penalización de Han  $\Theta_\sigma(x) = f(x) + \sigma \|c(x)^\#\|$ :

$$\Theta_\sigma(x + \alpha d_k) \leq \Theta_\sigma(x_k) + \omega \alpha \Delta_k$$

donde  $\omega \in (0, 0.5)$  es dado y

$$\Delta_k := -(d_k)^t B_k d_k + (\lambda_k^{PQ})^t c(x_k) - \sigma_k \|c(x_k)^\#\|$$

4. Hacer  $x_{k+1} = x_k + \alpha_k d_k$  y  $\lambda_{k+1} = \lambda_k + \alpha_k (\lambda_k^{PQ} - \lambda_k)$ .

5. Calcular:

$$\begin{aligned} \delta_k &= x_{k+1} - x_k \\ \gamma_k^\ell &= \nabla \ell(x^{k+1}, \lambda_k^{PQ}) - \nabla \ell(x_k, \lambda_k^{PQ}) \\ \gamma_k &= \theta \gamma_k^\ell + (1 - \theta) B_k \delta_k \end{aligned}$$

donde

$$\theta = \begin{cases} 1 & \text{si } (\gamma_k^\ell)^t \delta_k \geq 0.2 \delta_k^t B_k \delta_k \\ 0.8 \frac{\delta_k^t B_k \delta_k}{\delta_k^t B_k \delta_k - (\gamma_k^\ell)^t \delta_k} & \text{en otro caso} \end{cases}$$

Calcular  $B_{k+1}$  por la fórmula de BFGS:

$$B_{k+1} = B_k - \frac{B_k \delta_k \delta_k^t B_k}{\delta_k^t B_k \delta_k} + \frac{\gamma_k \gamma_k^t}{\gamma_k^t \delta_k}$$

### **Bibliografía básica:**

- D. BERTSEKAS : Nonlinear Programming. Athena Scientific. 1995.
- F. BONNANS - J. Ch. GILBERT - C. LEMARECHAL - C. SAGASTIZABAL : Optimisation Numérique: aspects théoriques et pratiques. SMAI-Springer Verlag, 1997.
- R. FLETCHER : Practical Methods of Optimization. John Wiley and Sons, 1987.
- P.E. GILL - W. MURRAY - M. WRIGHT : Practical Optimization. Academic Press, 1981.
- P.E. GILL - W. MURRAY - M. WRIGHT : Numerical linear Algebra and Optimization. Addison-Wesley, 1991.
- D. GOLDFARB - M. J. TODD : Linear Programming. En Handbook in OR & MS, Vol. 1. (G.L. Nemhauser et al., ed.). North-Holland, 1989.
- D.G. LUENBERGER : Programacin lineal y no lineal. Addison-Wesley Iberoamericana, 1989.
- M. MINOUX : Programmation Mathématique. Dunod, 1983.
- J. NOCEDAL - S.J. WRIGHT : Numerical Optimization. Springer, 1999.
- C. POLA : Algoritmos numéricos para la resolución de problemas de optimización con restricciones. Tesis de Doctorado, Universidad de Cantabria, 1992.