

Método de gradiente conjugado con precondicionamiento

Estos apuntes son casi una copia de los apuntes de Greg Fasshauer:

http://www.math.iit.edu/~fass/477577_Chapter_16.pdf

Objetivos. Estudiar la idea del método de gradiente conjugado precondicionado.

Requisitos. El método de gradiente conjugado. El número de condición de una matriz.

1. Introducción breve. Sea A una matriz simétrica positiva definida. Consideramos el sistema de ecuaciones $Ax = b$, donde b es algún vector dado. Se sabe que el método de gradiente conjugado para este sistema de ecuaciones converge mejor cuando la matriz A es *bien condicionada*, esto es, cuando su número condición no es muy grande. En algunos casos se puede construir una matriz positiva simétrica M tal que el producto $M^{-1}A$ es mucho mejor condicionado que la matriz original A .

2. Factorización de la matriz de precondicionamiento. Como M es simétrica y positiva definida, se puede encontrar una matriz L invertible tal que

$$M^{-1} = LL^{\top}.$$

Por ejemplo, para calcular L de manera explícita, uno puede primero calcular la factorización de Cholesky de la matriz M , y luego invertir el factor inferior izquierdo de la factorización de Cholesky. Es un procedimiento más costoso que resolver el sistema original $Ax = b$, y en algoritmo que vamos a deducir no se utilizará la matriz L en la forma explícita. Sin embargo, la matriz L sirve para entender el algoritmo.

3. Transformación del sistema. Transformamos el sistema $Ax = b$:

$$\begin{aligned} Ax = b &\iff M^{-1}Ax = M^{-1}b &\iff LL^{\top}Ax = LL^{\top}b \\ &\iff L^{\top}Ax = L^{\top}b &\iff L^{\top}ALL^{-1}x = L^{\top}b. \end{aligned}$$

Utilizamos la siguiente notación:

$$\hat{A} := L^{\top}AL, \quad \hat{x} := L^{-1}x, \quad \hat{b} := L^{\top}b.$$

Hemos mostrado que el sistema original $Ax = b$ es equivalente al sistema $\hat{A}\hat{x} = \hat{b}$. Es fácil verificar que la matriz \hat{A} es simétrica y positiva definida.

4. La matriz \widehat{A} es simétrica y positiva definida. En efecto,

$$\widehat{A}^\top = L^\top A^\top (L^\top)^\top = L^\top AL = \widehat{A},$$

y si $v \in \mathbb{R}^n \setminus \{\mathbf{0}_n\}$, entonces $Lv \neq \mathbf{0}_n$ y

$$v^\top \widehat{A}v = (Lv)^\top A(Lv) > 0.$$

Aplicamos el método de gradiente conjugado a la matriz \widehat{A} , pero transformemos las fórmulas del método de tal manera que en vez de \widehat{A} o L o \widehat{b} se utilicen solamente los objetos originales A , M y b .

5. Duda. En la introducción pedimos que sea pequeño el número $\kappa(M^{-1}A)$. No veo cómo relacionarlo con $\kappa(\widehat{A})$.

Deducción de las fórmulas del algoritmo

Escribimos las fórmulas principales del método de gradiente conjugado aplicado a la matriz \widehat{A} y el vector \widehat{b} . Luego transformamos estas fórmulas de tal manera que solamente se utilicen A , M y b .

6. Fórmula para el residuo. El residuo correspondiente al s -ésimo paso se puede escribir como

$$\widehat{r}_s = \widehat{b} - \widehat{A}\widehat{x}_s = L^\top b - (L^\top AL)L^{-1}x_s = L^\top r_s.$$

Denotemos por z_s al siguiente *residuo modificado*:

$$z_s := M^{-1}r_s.$$

7. La norma del residuo.

$$\|\widehat{r}_s\|^2 = (L^\top r_s)^\top (L^\top r_s) = r_s^\top LL^\top r_s = r_s^\top M^{-1}r_s = r_s^\top z_s. \quad (1)$$

8. Direcciones conjugadas. Denotamos por \widehat{p}_s a las direcciones en el método de gradiente conjugado aplicado a la matriz \widehat{A} . Se sabe que los vectores \widehat{p}_s son \widehat{A} -ortogonales. Pongamos

$$p_s := L\widehat{p}_s.$$

Notamos que los vectores p_s son A -ortogonales.

$$p_s^\top Ap_t = \widehat{p}_s^\top L^\top AL\widehat{p}_t. \quad (2)$$

Si $s \neq t$, entonces este producto es 0.

9. **Fórmula para la longitud del paso.** Por (1) y (2),

$$\hat{\alpha}_s = \frac{\hat{r}_s^\top \hat{r}_s}{\hat{p}_s^\top \hat{A} \hat{p}_s} = \frac{r_s^\top z_s}{p_s^\top A p_s}.$$

10. **Fórmula para el coeficiente de ortogonalización.** Notamos que

$$\hat{p}_s^\top \hat{r}_{s+1} = p_s^\top (L^{-1})^\top L^\top r_s = p_s^\top r_s.$$

Por eso

$$\hat{\beta}_{s+1} = \frac{\hat{p}_s^\top \hat{r}_{s+1}}{\hat{p}_s^\top \hat{A} \hat{p}_s} = \frac{p_s^\top r_{s+1}}{p_s^\top A p_s}. \quad (3)$$

11. **Renovación del vector.**

$$\hat{x}_{s+1} = \hat{x}_s + \alpha_s \hat{p}_s \iff L^{-1} x_{s+1} = L^{-1} x_s + \alpha_s L^{-1} p_s \iff x_{s+1} = x_s + \alpha_s p_s.$$

12. **Renovación del residuo.**

$$\begin{aligned} \hat{r}_{s+1} = \hat{r}_s - \alpha_s \hat{A} \hat{p}_s &\iff L^\top r_{s+1} = L^\top r_s - \alpha_s L^\top A L L^{-1} p_s \\ &\iff r_{s+1} = r_s - \alpha_s A p_s. \end{aligned}$$

13. **Renovación de la dirección.**

$$\begin{aligned} \hat{p}_{s+1} = \hat{r}_{s+1} + \beta_{s+1} \hat{p}_s &\iff L^{-1} p_{s+1} = L^{-1} r_{s+1} + \beta_{s+1} L^{-1} p_s \\ &\iff p_{s+1} = z_{s+1} + \beta_{s+1} p_s. \end{aligned}$$

Algoritmo

14. Método de gradiente conjugado con preconditionamiento, en el lenguaje Matlab/Octave. Supongamos que está dada una función `solveM` que resuelve sistemas de ecuaciones lineales con la matriz M . Por ejemplo, si M es una matriz dispersa, entonces se puede usar la función estándar para resolver sistemas:

```
solveM = @(w) M \ w;
```

Entonces el método de gradiente conjugado con el preconditionador M se puede programar así:

```
function [x, s] = precondconjgrad(A, b, tol, smax, solveM),
n = length(b);
x = zeros(n, 1);
r = b;
z = solveM(r);
p = z;
delta = r' * p;
nr = norm(r);
s = 0;
while (s < smax) && (nr >= tol),
    q = A * p;
    alpha = delta / (p' * q);
    x = x + alpha * p;
    rold = r;
    r = r - alpha * q;
    z = solveM(r);
    deltaold = delta;
    delta = r' * z;
    nr = norm(r);
    beta = delta / deltaold;
    p = z + beta * p;
    s = s + 1;
end
end
```