

**LABORATOR 6 - METODA GRADIENTILOR CONJUGAȚI.
METODA CELOR MAI MICI PĂTRATE**

1. METODA GRADIENTILOR CONJUGAȚI

Metoda gradientilor conjugati face parte din clasa metodelor de relaxare, ca urmare se aplică principiile generale studiate în cursul anterior. Fie deci sistemul $Ax = b$, unde A este simetrică și pozitiv definită.

Definiția 1. Spunem că direcțiile p și q sunt **direcții conjugate** în raport cu matricea A dacă $\langle Ap, q \rangle = \langle p, Aq \rangle = 0$.

Fie $v^{(0)}$ un vector de probă și $r^{(0)} = Av^{(0)} - b$ vectorul rezidual corespunzător. La metoda gradientilor conjugati pentru rezolvarea sistemului $Ax = b$, prima direcție de relaxare se alege $p^{(1)} = -r^{(0)}$. În continuare avem:

$$(1.1a) \quad t_{\min} = -\frac{\langle r^{(0)}, p^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle} = \frac{\langle r^{(0)}, r^{(0)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle},$$

$$(1.1b) \quad v^{(1)} = v^{(0)} + q_1 p^{(1)},$$

unde

$$(1.2) \quad q_1 = t_{\min} = -\frac{\langle r^{(0)}, p^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle}.$$

Valoarea minimă a funcției $F = F(v)$, când v parcurge dreapta ce trece prin $v^{(0)}$ și are direcția $p^{(1)} = -r^{(0)}$ este realizată în $v^{(1)}$. Fie

$$r^{(1)} = \text{grad } F(v^{(1)}) = Av^{(1)} - b.$$

Din **Observația 1** din cursul anterior rezultă că

$$(1.3) \quad \langle r^{(1)}, p^{(1)} \rangle = -\langle r^{(1)}, r^{(0)} \rangle = 0.$$

Următoarea direcție de relaxare $p^{(2)}$ se alege de forma $p^{(2)} = -r^{(1)} + c_1 p^{(1)}$ și în plus să fie conjugată direcției $p^{(1)}$ în raport cu A .

Așadar, avem:

$$0 = \langle Ap^{(2)}, p^{(1)} \rangle = \langle p^{(2)}, Ap^{(1)} \rangle = -\langle r^{(1)}, Ap^{(1)} \rangle + c_1 \langle Ap^{(1)}, p^{(1)} \rangle,$$

de unde rezultă

$$(1.4) \quad c_1 = \frac{\langle r^{(1)}, Ap^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle}.$$

Avem de asemenea

$$(1.5) \quad v^{(2)} = v^{(1)} + t_{\min} p^{(2)} = v^{(1)} - \frac{\langle r^{(1)}, p^{(2)} \rangle}{\langle Ap^{(2)}, p^{(2)} \rangle} p^{(2)}.$$

În general, pentru orice $k \geq 2$ obținem

$$(1.6) \quad c_{k-1} = \frac{\langle r^{(k-1)}, Ap^{(k-1)} \rangle}{\langle Ap^{(k-1)}, p^{(k-1)} \rangle},$$

$$(1.7) \quad p^{(k)} = -r^{(k-1)} + c_{k-1}p^{(k-1)}$$

$$(1.8) \quad q_k = -\frac{\langle r^{(k-1)}, p^{(k)} \rangle}{\langle Ap^{(k)}, p^{(k)} \rangle},$$

$$(1.9) \quad v^{(k)} = v^{(k-1)} + q_k p^{(k)}.$$

Metoda gradientilor conjugați este definită de formulele (1.6)-(1.9). În continuare prezentăm unele simplificări și proprietăți suplimentare.

Deoarece $r^{(k-1)}$ este ortogonal pe direcția $p^{(k-1)}$ rezultă

$$\langle r^{(k-1)}, p^{(k)} \rangle = \langle r^{(k-1)}, -r^{(k-1)} + c_{k-1}p^{(k-1)} \rangle = -\langle r^{(k-1)}, r^{(k-1)} \rangle$$

și deci

$$(1.10) \quad q_k = \frac{\langle r^{(k-1)}, r^{(k-1)} \rangle}{\langle Ap^{(k)}, p^{(k)} \rangle} > 0.$$

Pe de altă parte, din (1.9) avem

$$r^{(k)} = Av^{(k)} - b = Av^{(k-1)} - b + q_k Ap^{(k)} = r^{(k-1)} + q_k Ap^{(k)}.$$

Obținem deci următoarea relație de recurență:

$$(1.11) \quad r^{(k)} = r^{(k-1)} + q_k Ap^{(k)}.$$

Observăm că

$$(1.12) \quad \langle r^{(k)}, r^{(k-1)} \rangle = 0.$$

Într-adevăr, din (1.11) rezultă

$$(1.13) \quad \langle r^{(k)}, r^{(k-1)} \rangle = \langle r^{(k-1)}, r^{(k-1)} \rangle + q_k \langle r^{(k-1)}, Ap^{(k)} \rangle.$$

Pe de altă parte, tinând seama de (1.7) și (1.10) și de faptul că $p^{(k)}$ și $p^{(k-1)}$ sunt A -conjugate, avem

$$(1.14) \quad q_k \langle r^{(k-1)}, Ap^{(k)} \rangle = \langle r^{(k-1)}, r^{(k-1)} \rangle \frac{\langle r^{(k-1)}, Ap^{(k)} \rangle}{\langle Ap^{(k)}, -r^{(k-1)} + c_{k-1}p^{(k-1)} \rangle} = -\langle r^{(k-1)}, r^{(k-1)} \rangle.$$

Din (1.13) și (1.14) rezultă (1.12).

Deoarece $Ap^{(k)}$ oricum trebuie calculat, rezultă că vectorul rezidual $r^{(k)}$ se va calcula din relația de recurență (1.11) și nu prin înlocuirea directă a lui $v^{(k)}$ în expresia $Av = b$.

În continuare vom stabili o altă formulă pentru coeficientul c_{k-1} . Din (1.11) și (1.12) rezultă

$$\langle r^{(k-1)}, Ap^{(k-1)} \rangle = \left\langle r^{(k-1)}, \frac{1}{q_{k-1}}(r^{(k-1)} - r^{(k-2)}) \right\rangle = \frac{1}{q_{k-1}} \langle r^{(k-1)}, r^{(k-1)} \rangle.$$

Tinând seama de (1.6) și (1.10) obținem

$$c_{k-1} = \frac{\langle r^{(k-1)}, Ap^{(k-1)} \rangle}{\langle Ap^{(k-1)}, p^{(k-1)} \rangle} = \frac{\langle r^{(k-1)}, r^{(k-1)} \rangle}{\langle r^{(k-2)}, r^{(k-2)} \rangle}.$$

Are loc următorul rezultat:

Teorema 1. *La metoda gradientilor conjugați direcțiile de relaxare $p^{(k)}$, $k = 1, 2, \dots$ sunt conjugate două câte două în raport cu matricea A , iar vectorii reziduali $r^{(k)}$, $k = 0, 1, \dots$ sunt ortogonali doi câte doi.*

Demonstrație. Demonstrația se face prin inducție după k . Pentru $k = 1$ avem $\langle r^{(1)}, r^{(0)} \rangle = 0$ din (1.3), iar pentru prima afirmație nu avem ce arăta. Ipoteza inductivă este:

$$(1.15) \quad \langle r^{(i)}, r^{(j)} \rangle = 0, \text{ pentru } i \neq j, 0 \leq i, j \leq k$$

$$(1.16) \quad \langle p^{(i)}, Ap^{(j)} \rangle = 0, \text{ pentru } i \neq j, 1 \leq i, j \leq k.$$

Trebuie să arătăm că

$$(1.17) \quad \langle r^{(k+1)}, r^{(j)} \rangle = 0, \text{ pentru } 0 \leq j \leq k$$

$$(1.18) \quad \langle p^{(k+1)}, Ap^{(j)} \rangle = 0, \text{ pentru } 1 \leq j \leq k.$$

Dacă $j = k$, atunci $\langle p^{(k+1)}, Ap^{(k)} \rangle = \langle Ap^{(k+1)}, p^{(k)} \rangle = 0$ deoarece $p^{(k+1)}$ și $p^{(k)}$ sunt A -conjugate. Fie $1 \leq j < k$; atunci folosind (1.16)

$$\langle p^{(k+1)}, Ap^{(j)} \rangle = \langle -r^{(k)} + c_{k-1}p^{(k)}, Ap^{(j)} \rangle = \langle -r^{(k)}, Ap^{(j)} \rangle.$$

Dar $Ap^{(j)} = \frac{1}{q_j}(r^{(j)} - r^{(j-1)})$ și din (1.15) obținem $\langle p^{(k+1)}, Ap^{(j)} \rangle = 0$. Am demonstrat (1.18).

Pentru $j = k$, (1.17) este adevărată din (1.12). Fie $0 \leq j < k$. Din (1.11) și (1.15) rezultă

$$\begin{aligned} \langle r^{(k+1)}, r^{(j)} \rangle &= \langle r^{(k)} + q_{k+1}Ap^{(k+1)}, r^{(j)} \rangle = q_{k+1} \langle Ap^{(k+1)}, r^{(j)} \rangle \\ &= q_{k+1} \langle Ap^{(k+1)}, -p^{(j+1)} + c_j p^{(j)} \rangle. \end{aligned}$$

Folosind relația (1.18) și faptul că A este simetrică, rezultă $\langle r^{(k+1)}, r^{(j)} \rangle = 0$ și cu aceasta teorema este demonstrată. \square

Din **Teorema 1** rezultă că vectorii reziduali $r^{(k)}$ sunt ortogonali doi câte doi și deci liniar independenți dacă sunt nenuli. Cum nu pot exista decât cel mult n vectori liniar independenți, rezultă că teoretic ar trebui să obținem soluția exactă în cel mult n pași. În practică nu se realizează acest lucru din cauza erorilor de calcul care intervin și care fac ca vectorii $r^{(k)}$ să nu formeze un sistem ortogonal. În concluzie, se continuă calculul lui $r^{(k)}$ până devine foarte mic sau nul, deoarece valoarea funcției pătratice $F(v)$ se micșorează la fiecare pas.

Metoda gradientilor conjugați se dovedește foarte utilă pentru sistemele în care matricea A are multe zerouri și fiecare ecuație are o anumită regularitate internă. Astfel de sisteme apar în procesul de discretizare a problemei la limită a ecuațiilor cu derivate parțiale de tip eliptic.

Algoritmul MATLAB pentru metoda gradientilor conjugați

```
clc
% Introducere A,b,n
```

```

x=zeros(n,1);
r=A*x-b;
for i=1:n
    i
    if (i==1)
        p=-r
    else
        c=(r'*A*p)/(p'*A*p)
        p=-r+c*p
    end
    q=(r'*r)/(p'*A*p)
    x=x+q*p
    r=r+q*A*p
end
disp('Solutia aproximativa a sistemului prin metoda gradientilor conjugați')
x
fprintf('\neste obtinuta la pasul %g.\n',i);
disp('Verificare')
A*x

```

2. METODA CELOR MAI MICI PĂTRATE

În procesul de prelucrare a datelor, apar sisteme de ecuații supradimensionate și subdimensionate. Abordăm pentru început problema sistemelor supradimensionate. Fie sistemul:

$$(2.1) \quad \begin{cases} a_{11}x_1 + \dots + a_{1n}x_n = b_1 \\ \dots \\ a_{m1}x_1 + \dots + a_{mn}x_n = b_m \end{cases}, m > n.$$

Evident, un asemenea sistem este posibil să nu aibă soluție. Fie

$$(2.2) \quad r = Ax - b = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_m \end{bmatrix}$$

vectorul rezidual, unde

$$r_i = a_{i1}x_1 + \dots + a_{in}x_n, i = 1, \dots, m.$$

Considerăm funcția pătratică:

$$(2.3) \quad f(x) = f(x_1, \dots, x_n) = \langle r, r \rangle = r_1^2 + r_2^2 + \dots + r_m^2.$$

Definiția 2. Se numește **soluție în sensul celor mai mici pătrate** a sistemului (2.1) acel vector x^* pentru care funcția (2.3) are valoarea minimă.

Dacă $\min_{x \in \mathbb{R}^n} f(x) = f(x^*) = 0$, atunci $r_i(x^*) = 0$, pentru orice $i = 1, \dots, m$. Rezultă că sistemul (2.1) este compatibil și $x = x^*$ este soluția sa exactă.

În general, sistemul (2.1) nu este compatibil și $\min_{x \in \mathbb{R}^n} f(x) = f(x^*) > 0$, iar $x = x^*$ este un substitut pentru soluția sistemului și anume soluția în sensul celor mai mici pătrate.

Funcția f se poate pune sub forma

$$(2.4) \quad \begin{aligned} f(x) &= \langle r, r \rangle = \langle Ax - b, Ax - b \rangle = \langle Ax, Ax \rangle - 2 \langle Ax, b \rangle + \langle b, b \rangle \\ &= \langle A^T Ax, x \rangle - 2 \langle A^T b, x \rangle + \langle b, b \rangle. \end{aligned}$$

Teorema 2. *Dacă $\text{rang}(A) = n$, atunci sistemul (2.1) admite o unică soluție în sensul celor mai mici pătrate și aceasta este soluția (unică) a sistemului*

$$(2.5) \quad A^T Ax = A^T b.$$

*Sistemul (2.5) se numește **sistemul normal al lui Gauss**.*

Demonstrație. Punctele de extrem ale funcției f se găsesc printre punctele critice, adică $\text{grad } f(x_0) = 0$ dacă x_0 este punct de extrem, echivalent $A^T Ax_0 - A^T b = 0$. Cum $\text{rang}(A) = \text{rang}(A^T) = \text{rang}(A^T A) = n$, obținem că sistemul (2.5) admite o unică soluție x^* , care este punct critic pentru f .

Matricea $B = A^T A$ este simetrică și semipozitiv definită. Dacă presupunem că $\langle Bx, x \rangle = 0$, obținem $\langle Ax, Ax \rangle = 0$, deci $Ax = 0$. Cum $\text{rang}(A) = n < m$, avem $x = 0$, deci B este pozitiv definită. Deoarece $d^2 f(x) = 2 \sum_{i=1}^n \sum_{j=1}^n b_{ij} dx_i dx_j$, pentru orice x , obținem că diferențiala de ordinul doi este pozitiv definită, deci unicul punct critic x^* este punct de minim pentru f . \square

Așadar, în ipoteza $\text{rang}(A) = n$, soluția sistemului (2.1), în sensul celor mai mici pătrate, este unică și este soluția sistemului (2.5). Acest sistem este simetric și pozitiv definit, așadar se rezolvă prin metoda Cholesky sau una din metodele de relaxare.

Observația 1. *Soluția sistemului (2.5) este $x^* = (A^T A)^{-1} A^T b$. Matricea $P = (A^T A)^{-1} A^T$ se numește **pseudoinversa** matricii (dreptunghiulare) A . Dacă A este pătratică, obținem $P = A^{-1} (A^T)^{-1} A^T = A^{-1}$, deci noțiunea de pseudoinversă generalizează noțiunea de matrice inversă pentru matrici dreptunghiulare.*

Exemplul 1. Dreapta de regresie

Să presupunem că vrem să găsim o dreaptă $y = mx + n$ care să treacă prin punctele

$$M_1(0, 0), M_2(2, 1), M_3(5, 3), M_4(8, 5), M_5(10, 6).$$

Se obține astfel sistemul

$$(2.6) \quad \begin{cases} 0 \cdot m + n = 0 \\ 2 \cdot m + n = 1 \\ 5 \cdot m + n = 3 \\ 8 \cdot m + n = 5 \\ 10 \cdot m + n = 6 \end{cases}.$$

Sistemul (2.6) este supradimensionat și incompatibil. Avem:

$$A = \begin{bmatrix} 0 & 1 \\ 2 & 1 \\ 5 & 1 \\ 8 & 1 \\ 10 & 1 \end{bmatrix}, b = \begin{bmatrix} 0 \\ 1 \\ 3 \\ 5 \\ 6 \end{bmatrix}, B = A^T A = \begin{bmatrix} 193 & 25 \\ 25 & 5 \end{bmatrix}, A^T b = \begin{bmatrix} 117 \\ 15 \end{bmatrix}.$$

Ecuatiile normale ale lui Gauss sunt:

$$\begin{cases} 193m + 25n = 117 \\ 25m + 5n = 15 \end{cases} .$$

Soluția exactă este $m = \frac{21}{34}$, $n = -\frac{3}{34}$, iar dreapta de regresie este $y = \frac{21}{34}x - \frac{3}{34}$. Această dreaptă nu trece prin punctele M_i , dar este cea dreaptă din plan care trece (într-un anumit sens) cel mai aproape de aceste puncte.

Sistemele subdimensionate apar în probleme legate de ajustarea datelor. Să presupunem că măsurând n cantități x_1, x_2, \dots, x_n găsim valorile l_1, l_2, \dots, l_n . Pe de altă parte, necunoscutele x_1, x_2, \dots, x_n satisfac anumite ecuații, și anume:

$$(2.7) \quad \begin{cases} a_{11}x_1 + \dots + a_{1n}x_n = b_1 \\ \dots \\ a_{m1}x_1 + \dots + a_{mn}x_n = b_m \end{cases}, m < n.$$

Datorită lipsei de acuratețe a măsurătorilor se pune condiția ca sumele pătratelor corecțiilor $\sum_{i=1}^n (l_i - x_i)^2$ să fie minimă. Se obține astfel o problemă de extrem cu legături.

Exemplul 2. Să presupunem că măsurând unghiurile unui triunghi x_1, x_2, x_3 găsim valorile l_1, l_2, l_3 . Evident avem legătura $x_1 + x_2 + x_3 = \pi$. Impunem condiția ca abaterile datorate impreciziei măsurătorilor să fie cât mai mici, deci $(x_1 - l_1)^2 + (x_2 - l_2)^2 + (x_3 - l_3)^2$ să fie minimă.

Revenind la cazul general, se pune problema să determinăm n necunoscute x_1, x_2, \dots, x_n care satisfac legăturile (2.7) și care minimizează funcția:

$$f(x_1, \dots, x_n) = (x_1 - l_1)^2 + \dots + (x_n - l_n)^2.$$

Considerăm funcția auxiliară

$$\begin{aligned} \Phi(x_1, \dots, x_n, \lambda_1, \dots, \lambda_m) &= (x_1 - l_1)^2 + \dots + (x_n - l_n)^2 \\ &\quad + \lambda_1(a_{11}x_1 + \dots + a_{1n}x_n - b_1) \\ &\quad + \dots + \lambda_m(a_{m1}x_1 + \dots + a_{mn}x_n - b_m). \end{aligned}$$

Punctele critice ale funcției Φ sunt date de sistemul

$$(2.8) \quad \begin{cases} 2(x_1 - l_1) + (a_{11}\lambda_1 + \dots + a_{m1}\lambda_m) = 0 \\ \dots \\ 2(x_n - l_n) + (a_{1n}\lambda_1 + \dots + a_{mn}\lambda_m) = 0 \\ a_{11}x_1 + \dots + a_{1n}x_n - b_1 = 0 \\ \dots \\ a_{m1}x_1 + \dots + a_{mn}x_n - b_m = 0 \end{cases} .$$

Dacă notăm $l = [l_1, \dots, l_m]^T$ și $\lambda = [\lambda_1, \dots, \lambda_m]^T$, atunci sistemul 2.8 se scrie sub forma matriceală:

$$(2.9) \quad x = \frac{1}{2}A^T\lambda + l$$

$$(2.10) \quad Ax = b$$

Înlocuind (2.9) în (2.10) obținem sistemul:

$$(2.11) \quad \frac{1}{2}AA^T\lambda = b - Al.$$

Dacă $\text{rang}(A) = m$, atunci $\text{rang}(A^T A) = m$ și sistemul (2.11) are soluție unică. Mai mult, matricea AA^T este pătratică, simetrică și pozitiv definită, deci rezolvarea sistemului (2.11) se poate face cu metoda Cholesky sau cu una din metodele de relaxare. Rezolvând sistemul (2.11) obținem multiplicatorii Lagrange $\lambda_1, \dots, \lambda_m$, iar din relația $x = \frac{1}{2}A^T\lambda + l$ determinăm punctul de minim condiționat al funcției f (cum $d^2\Phi = 2(dx_1^2 + \dots + dx_n^2) > 0$ rezultă că avem într-adevăr un punct de minim).