

Algoritmi numerici pentru optimizare III - Algoritmi determinați de ordin superior

Prof.dr.ing. Gabriela Ciuprina

Universitatea "Politehnica" București, Facultatea de Inginerie Electrică,
Departamentul de Electrotehnică

Suport didactic pentru disciplina *Algoritmi Numerici*, 2017-2018

Notes

Cuprins

- 1 Introducere
- 2 Optimizare unidimensională
 - Condiții necesare și suficiente
 - Metoda aproximării parabolice (Newton, falsa poziție, interpolare)
 - Metoda aproximării cubice
- 3 Optimizare multidimensională
 - Metoda Newton
 - Metoda gradientului
 - Metoda gradientilor conjugați
 - Metode cvasi-Newton
- 4 Exemple din mediile în care lucați
 - COMSOL
 - MATLAB

Notes

Formularea problemei

Să se găsească n parametri independenți, notați $x_1^*, x_2^*, \dots, x_n^*$, pentru care expresia E este minimă, unde

$$E = f(x_1, x_2, \dots, x_n), \quad (1)$$

și $f : \Omega \rightarrow \mathbb{R}$, $\Omega \subset \mathbb{R}^n$, este dată.

Pe scurt:

$$(x_1^*, x_2^*, \dots, x_n^*) = \arg \min f(x_1, x_2, \dots, x_n). \quad (2)$$

Notății

$$\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \Omega. \quad (3)$$

$$\mathbf{x}_{\min} = [x_1^*, x_2^*, \dots, x_n^*]^T \in \Omega \quad (4)$$

$$\mathbf{x}_{\min} = \arg \min f(\mathbf{x}), \quad \mathbf{x} \in \Omega$$

$$E_{\min} = f(\mathbf{x}_{\min}).$$

Notes

Minime globale/locale

$$\mathbf{x}_{\min} = \arg \min f(\mathbf{x}), \quad \mathbf{x} \in \Omega \quad (5)$$

$$E_{\min} = \min \{ f(\mathbf{x}) \mid \mathbf{x} \in \Omega \} \quad (6)$$

\mathbf{x}_{\min} este *minim global* dacă

$$E_{\min} \leq f(\mathbf{x}), \quad \forall \mathbf{x} \in \Omega \quad (7)$$

- dacă $E_{\min} \leq f(\mathbf{x})$ doar într-o vecinătate a lui \mathbf{x}_{\min} atunci minimul este *local*.
- în practică este dificil de stabilit dacă un minim găsit este local sau global;
- minimul global s-ar putea să nu fie unic.

Notes

Metode de optimizare

I. Deterministe - conduc la aceeași soluție pentru rulări diferite ale programului, dacă pornesc din aceleași condiții inițiale și au aceiași parametri.

- Dezavantaj: ?
- Avantaj: ?

Pot fi

- 1 de ordin zero
- 2 de ordin superior (1,2) Ex: metoda Newton; metoda falsei poziții; metoda gradientului (a celei mai rapide coborâri); metoda gradientilor conjugați; metode cvasi-Newton, etc.

II. Stocastice

Notes

Metode de optimizare

$$(x_1^*, x_2^*, \dots, x_n^*) = \arg \min f(x_1, x_2, \dots, x_n). \quad (8)$$

"Optimizare 1D": $n = 1$

"Optimizare nD": $n > 1$

Metode

- **de căutare** = intervalul care conține minimumul este micșorat prin evaluarea lui f în anumite puncte;
- **de aproximare** = funcția de optimizat este aproximată printr-o funcție cunoscută care poate fi analizată ușor.

Notes

Metode de aproximare

Ideea: se aproximează local relieful funcției cu o funcție polinomială de grad mic, căreia i se poate determina ușor minimul.

Metodele se numesc:

- **de ordinul 1** - dacă necesită evaluarea primei derivate a funcției obiectiv;
- **de ordinul 2** - dacă necesită evaluarea celei de a doua derivate a funcției obiectiv;
- etc.

Notes

Condiții necesare și suficiente - 1D

Fie $f : \mathbb{R} \rightarrow \mathbb{R}$ cu derivate de ordinul 1 și 2 continue.

Condiția necesară de minim

Dacă x^* este un minim local al lui f atunci el este un punct critic pentru f :

$$\frac{df}{dx}(x^*) = 0.$$

Condiția suficientă de minim

Dacă

$$\frac{df}{dx}(x^*) = 0 \quad \text{și} \quad \frac{d^2f}{dx^2}(x^*) > 0.$$

atunci x^* este un punct de minim local pentru f ,

Obs:

- Dacă $d^2f/dx^2(x^*) < 0$ atunci punctul este de maxim.
- Dacă $d^2f/dx^2(x^*) = 0$ testul derivatei a doua nu este concludent și trebuie folosită dezvoltarea în serie Taylor pentru a analiza funcția.

Notes

Metoda aproximării parabolice

Ideea:

- se aproximează funcția de minimizat $f(x)$ în jurul punctului de minim cu o parabolă $q(x)$ și se alege minimul parabolei ca fiind o aproximare pentru minimul căutat;
- procedeul continuă iterativ până când derivata funcției este neglijabilă în minimul aproximativ.

Parabola $q(x)$ e determinată de trei puncte \Rightarrow este nevoie de trei informații

\Rightarrow există mai multe variante

Notes

Metoda aproximării parabolice

a) Metoda Newton

Cele trei informații sunt legate de același punct x_k (valoarea funcției, derivatei de ordinul 1 și a celei de ordinul 2).

Condiții impuse:

$$q(x_k) = f(x_k), \quad (9)$$

$$q'(x_k) = f'(x_k), \quad (10)$$

$$q''(x_k) = f''(x_k). \quad (11)$$

\Rightarrow

$$q(x) = f(x_k) + f'(x_k)(x - x_k) + \frac{f''(x_k)}{2}(x - x_k)^2. \quad (12)$$

Notes

Metoda aproximării parabolice

a) Metoda Newton

$$q(x) = f(x_k) + f'(x_k)(x - x_k) + \frac{f''(x_k)}{2}(x - x_k)^2. \quad (13)$$

Estimarea x_{k+1} se obține din condiția $q'(x_k + 1) = 0$, unde

$$q'(x) = f'(x_k) + f''(x_k)(x - x_k)$$

$$f'(x_k) + f''(x_k)(x_{k+1} - x_k) = 0$$

⇒

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)} \quad (14)$$

Notes

Metoda aproximării parabolice

a) Metoda Newton

- Noua iterație nu depinde de valoarea funcției în x_k ;
- Este o metodă de ordinul doi;
- Metoda Newton a fost prezentată și ca metodă de rezolvare a ecuațiilor neliniare.

$$g(x) = 0 \Leftrightarrow \min f(x)$$

dacă $g(x) = f'(x)$.

$$x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)} \Leftrightarrow x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$$

Notes

Metoda aproximării parabolice

b) Metoda falsei poziții

Condiții impuse:

$$q(x_k) = f(x_k), \quad (15)$$

$$q'(x_k) = f'(x_k), \quad (16)$$

$$q'(x_{k-1}) = f'(x_{k-1}). \quad (17)$$

⇒

$$q(x) = f(x_k) + f'(x_k)(x - x_k) + c(x - x_k)^2 \quad (18)$$

$$q'(x) = f'(x_k) + 2c(x - x_k) \quad (19)$$

c se determină impunând (17).

Notes

Metoda aproximării parabolice

⇒

$$c = \frac{f'(x_{k-1}) - f'(x_k)}{2(x_{k-1} - x_k)}$$

⇒

$$q(x) = f(x_k) + f'(x_k)(x - x_k) + \frac{f'(x_{k-1}) - f'(x_k)}{(x_{k-1} - x_k)} \frac{(x - x_k)^2}{2} \quad (20)$$

Comparând cu Newton - derivata a doua \approx formulă de diferențe finite, de ordinul 1.

$g'(x) = 0 \Rightarrow$

$$x_{k+1} = x_k - f'(x_k) \frac{x_{k-1} - x_k}{f'(x_{k-1}) - f'(x_k)} \quad (21)$$

Notes

Metoda aproximării parabolice

b) Metoda falsei poziții

- Noua iterație nu depinde de valoarea funcției în x_k ;
- Este o metodă de ordinul unu;
- Metoda falsei poziții pentru minimizare este metoda secantei pentru rezolvarea unei ecuații neliniare.

$$g(x) = 0 \Leftrightarrow \min f(x)$$

dacă $g(x) = f'(x)$.

$$x_{k+1} = x_k - g(x_k) \frac{x_k - x_{k-1}}{g(x_k) - g(x_{k-1})} \Leftrightarrow x_{k+1} = x_k - f'(x_k) \frac{x_{k-1} - x_k}{f'(x_{k-1}) - f'(x_k)}$$

Notes

Metoda aproximării parabolice

c) Metoda interpolării parabolice

Condiții impuse:

$$q(x_k) = f(x_k), \quad (22)$$

$$q(x_{k-1}) = f(x_{k-1}), \quad (23)$$

$$q(x_{k-2}) = f(x_{k-2}) \quad (24)$$

\Rightarrow

$$\begin{aligned} q(x) = & \frac{(x - x_{k-1})(x - x_{k-2})}{(x_k - x_{k-1})(x_k - x_{k-2})} f(x_k) + + \\ & + \frac{(x - x_k)(x - x_{k-2})}{(x_{k-1} - x_k)(x_{k-1} - x_{k-2})} f(x_{k-1}) + \\ & + \frac{(x - x_k)(x - x_{k-1})}{(x_{k-2} - x_k)(x_{k-2} - x_{k-1})} f(x_{k-2}) \quad (25) \end{aligned}$$

$q'(x) = 0 \Rightarrow x_{k+1}$ **Metode de ordin zero**

Notes

Metoda aproximării parabolice

Observații:

- **Inițializarea** este simplă la Newton, dublă la falsa poziție și triplă la interpolarea polinomială;
- **Ordinul metodei de optimizare** este 2 la Newton, 1 la falsa poziție și 0 la inițializarea polinomială.
- La orice metodă estimările pot conduce către un punct staționar (maxim sau de inflexiune) nedorit, de aceea algoritmul trebuie completat cu **pași suplimentari de testare și corectare**.
- Toate aceste metode sunt exacte pentru funcții parabolice.
- **Efortul de calcul pe iterație**: Newton (o derivată de ordin 1 și una de ordin 2), falsa poziție (o derivată de ordin 1), interpolarea parabolică (o evaluare de funcție).

Notes

Metoda aproximării parabolice - algoritm

funcție [real x_{\min}, f_{\min} , întreg n_{iter}] = **opt_falsa_pozitie**(real x_1, x_2 ,
funcție f , **funcție** f_{der} , întreg NMAX, real EPS)

```
stopval = 1.e + 4  
fdvec(1) = f_der(x1)  
x(1) = x1  
fdvec(2) = f_der(x2)  
x(2) = x2  
k = 2
```

```
cât timp ( $k \leq \text{NMAX}$  și  $\text{stopval} \geq \text{EPS}$ )  
     $x(k+1) = x(k) - \text{fdvec}(k) * (x(k-1) - x(k)) / (\text{fdvec}(k-1) - \text{fdvec}(k))$   
     $\text{fdvec}(k+1) = f\_der(x(k+1))$   
     $\text{stopval} = |\text{fdvec}(k+1)|$   
     $k = k + 1$ 
```

```
 $x_{\min} = x(k)$   
 $f_{\min} = f(x(k))$   
 $n_{\text{iter}} = k - 2$   
retur
```

Notes

Metoda aproximării cubice

Aproximarea locală se face cu un polinom de gradul 3.

Condiții impuse:

$$q(x_k) = f(x_k), \quad (26)$$

$$q'(x_k) = f'(x_k), \quad (27)$$

$$q(x_{k-1}) = f(x_{k-1}), \quad (28)$$

$$q'(x_{k-1}) = f'(x_{k-1}) \quad (29)$$

⇒

$$x_{k+1} = x_k - (x_k - x_{k-1}) \left[\frac{f'(x_k) + u_2 - u_1}{f'(x_k) - f'(x_{k-1}) + 2u_2} \right] \quad (30)$$

unde

$$u_1 = f'(x_{k-1}) + f'(x_k) - 3 \frac{f(x_{k-1}) - f(x_k)}{x_{k-1} - x_k}, \quad (31)$$

$$u_2 = \sqrt{u_1^2 - f'(x_{k-1})f'(x_k)}. \quad (32)$$

Notes

Condiții necesare și suficiente - nD

Fie $f : \mathbb{R}^n \rightarrow \mathbb{R}$ cu derivate de ordinul 1 și 2 continue.

Condiția necesară de minim

Dacă \mathbf{x}^* este un minim local al lui f atunci el este un punct critic pentru f :

$$\frac{\partial f}{\partial x_j}(\mathbf{x}^*) = 0, \quad \forall j = 1, \dots, n.$$

⇔ vectorul gradient să fie nul.

$$\nabla f(\mathbf{x}^*) = \mathbf{0} \quad (33)$$

Condiția suficientă de minim

Matricea Hessian să fie pozitiv definită în punctul critic

$$\nabla^2 f(\mathbf{x}^*) > \mathbf{0} \quad (34)$$

Notes

Metoda Newton

Taylor:

$$f(\mathbf{x}) = f(\mathbf{x}_k) + (\mathbf{x} - \mathbf{x}_k)^T \nabla f(\mathbf{x}_k) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_k)^T \nabla^2 f(\mathbf{x}_k) (\mathbf{x} - \mathbf{x}_k) + \dots \quad (35)$$

unde $\mathbf{x}, \mathbf{x}_k \in \mathbb{R}^n$.

$$f(\mathbf{x}) \approx g(\mathbf{x})$$

unde

$$g(\mathbf{x}) = f(\mathbf{x}_k) + (\mathbf{x} - \mathbf{x}_k)^T \mathbf{g}_k + \frac{1}{2} (\mathbf{x} - \mathbf{x}_k)^T \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k) \quad (36)$$

unde am notat $\mathbf{f}_k = f(\mathbf{x}_k)$, $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$, $\mathbf{H}_k = \nabla^2 f(\mathbf{x}_k)$

Notes

Metoda Newton

$$q(\mathbf{x}) = f(\mathbf{x}_k) + (\mathbf{x} - \mathbf{x}_k)^T \mathbf{g}_k + \frac{1}{2} (\mathbf{x} - \mathbf{x}_k)^T \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k) \quad (37)$$

Se impune condiția

$$\nabla q(\mathbf{x}) = 0 \quad \mathbf{x}_{k+1}$$

$$\nabla q(\mathbf{x}) = \mathbf{g}_k + \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k)$$

⇒

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_k^{-1} \mathbf{g}_k \quad (38)$$

Notes

Metoda gradientului

Acum pornim direct cu optimizarea funcției neliniare $f(\mathbf{x})$
 Ideea: $f(\mathbf{x}) \approx l(\mathbf{x})$ (aproximarea de ordinul 1)¹

$$l(\mathbf{x}) = f_k + (\mathbf{x} - \mathbf{x}_k)^T \mathbf{g}_k$$

La o nouă iterație \mathbf{x}_{k+1} , valoarea funcției

$$f_{k+1} \approx f_k + (\mathbf{x}_{k+1} - \mathbf{x}_k)^T \mathbf{g}_k$$

Deci $\Delta f \approx \Delta \mathbf{x}^T \mathbf{g}_k$.

Doresc o scădere maximă \Rightarrow o valoare maximă a produsului scalar dintre $\Delta \mathbf{x}$ și $\mathbf{g}_k \Rightarrow \Delta \mathbf{x}$ trebuie să aibă direcția vectorului gradient și sens opus acestuia.

Notăm

$$\Delta \mathbf{x} = -\alpha \mathbf{g} = \alpha \mathbf{v}$$

unde $\alpha \in \mathbb{R}_+$, \mathbf{v} - direcția de căutare.

¹Notăm iterația ca indice.

Notes

Metoda gradientului

În concluzie ideea metodei gradientului se bazează pe construcția

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$$

unde

$$\mathbf{v}_k = -\mathbf{g}_k = -\nabla f(\mathbf{x}_k)$$

iar α_k se determină la fiecare iterație a.î. să se minimizeze funcția f după direcția \mathbf{v}_k care trece prin \mathbf{x}_k , adică funcția 1D $t(\alpha)$

$$\min t(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{v}_k) \Rightarrow \alpha_k$$

Se pot aplica metode de minimizare 1D.

Notes

Căutarea valorii optime pentru α

- Dacă minimizarea liniară este exactă, atunci direcțiile consecutive din metoda gradientului sunt perpendiculare

$$\mathbf{g}_{k+1}^T \mathbf{v}_k = \mathbf{v}_k^T \mathbf{g}_{k+1} = 0. \quad (42)$$

- Căutarea liniară a lui α_k s-ar putea elimina dacă se cunoaște Hessianul H

$$f(\mathbf{g}_k + \alpha \mathbf{v}_k) \approx f(\mathbf{x}_k) + (\alpha \mathbf{v}_k)^T \mathbf{g}_k + \frac{1}{2} (\alpha \mathbf{v}_k)^T \mathbf{H}_k (\alpha \mathbf{v}_k)$$


$$t(\alpha) \approx q(\alpha) \quad q(\alpha) = f(\mathbf{x}_k) - \alpha \mathbf{g}_k^T \mathbf{g}_k + \frac{1}{2} \alpha^2 \mathbf{g}_k^T \mathbf{H}_k \mathbf{g}_k$$

$$q'(\alpha) = 0 \Rightarrow \alpha'_k = - \frac{\mathbf{v}_k^T \mathbf{g}_k}{\mathbf{g}_k^T \mathbf{H}_k \mathbf{g}_k} = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_k^T \mathbf{H}_k \mathbf{g}_k} \quad (43)$$

27/64

Notes

Căutarea valorii optime pentru α



α_k - prin căutare liniară.

α'_k obținută cu (43)

Care este mai bună ?

Funcția f și aproximările sale pe direcția \mathbf{v}_k .

28/64

Notes

Condiția de oprire

Variante:

- funcție

$$\frac{|f_{k+1} - f_k|}{1/2(|f_{k+1}| + |f_k| + \text{EPS})} < \text{ftol}. \quad (44)$$

EPS - zeroul mașinii, introdus pentru a evita împărțirea la zero.

- pas

$$\frac{\|\mathbf{x}_{k+1} - \mathbf{x}_k\|}{\|\mathbf{x}_1 - \mathbf{x}_0\|} < \text{xtol}. \quad (45)$$

- gradient

$$\|\mathbf{g}_{k+1}\| < \text{gtol}. \quad (46)$$

Notes

Algoritmul general al metodei gradientului

1. Alege \mathbf{x}_0

$$k = 0$$

Calculează $\mathbf{g}_0 = \nabla f(x_0)$

2. repetă

2.1. $\mathbf{v}_k = -\mathbf{g}_k$

2.2. Minimizează $t(\alpha) = f(\mathbf{x}_k + \alpha\mathbf{v}_k)$ în raport cu $\alpha \Rightarrow \alpha_k$

2.3. $\mathbf{p}_k = \alpha_k\mathbf{v}_k$

2.4. $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{p}_k$

2.5. Calculează $\mathbf{g}_{k+1} = \nabla f(x_{k+1})$

2.6 $k = k + 1$

până când este îndeplinită condiția de oprire


În capitolul de rezolvări de sisteme liniare, algoritmul era particularizat pentru funcții pătratice

$$f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T\mathbf{A}\mathbf{x} - \mathbf{b}^T\mathbf{x} + c$$

Notes

Efortul de calcul

Efort de calcul mare - chiar și pentru o funcție pătratică



Notes

Metoda gradientilor conjugați

Direcția de căutare depinde atât de direcția gradientului, cât și de direcția de căutare anterioară²

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad k > 0, \quad (47)$$

Primul pas este ca la metoda gradientului:

$$\mathbf{v}_0 = -\mathbf{g}_0$$

Direcțiile \mathbf{v}_k sunt alese să fie H-conjugate (sau H-ortogonale):

$$\mathbf{v}_{k+1}^T \mathbf{H}_k \mathbf{v}_j = 0, \quad (\forall) j \leq k. \quad (48)$$

²Revedeți și prezentarea de la sisteme algebrice liniare.

Notes

Metoda gradientilor conjugați

Determinăm β înlocuind (47) în (48).

$$\mathbf{v}_{k+1}^T \mathbf{H}_k \mathbf{v}_j = 0, \quad (\forall) j \leq k.$$

$$j = k \Rightarrow \mathbf{v}_{k+1}^T \mathbf{H}_k \mathbf{v}_k = 0$$

$$(-\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k)^T \mathbf{H}_k \mathbf{v}_k = 0$$

\Rightarrow

$$\beta_k = \frac{\mathbf{g}_{k+1}^T \mathbf{H}_k \mathbf{v}_k}{\mathbf{v}_k^T \mathbf{H}_k \mathbf{v}_k}, \quad (49)$$

Necesită calculul Hessianului la fiecare iterație - foarte costisitor, se procedează altfel:

Notes

Metoda gradientilor conjugați

Folosind aproximația de ordinul doi pentru funcția f

$$f(\mathbf{x}) \approx q(\mathbf{x}), \quad q(\mathbf{x}) = f_k + (\mathbf{x} - \mathbf{x}_k)^T \mathbf{g}_k + \frac{1}{2} (\mathbf{x} - \mathbf{x}_k)^T \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k)$$

\Rightarrow

$$\nabla f(\mathbf{x}) \approx \nabla q(\mathbf{x}), \quad \nabla q(\mathbf{x}) = \mathbf{g}_k + \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k)$$

\Rightarrow pentru $\mathbf{x} = \mathbf{x}_{k+1}$

$$\mathbf{g}_{k+1} \approx \mathbf{g}_k + \mathbf{H}_k (\mathbf{x}_{k+1} - \mathbf{x}_k) \Rightarrow \mathbf{g}_{k+1} \approx \mathbf{g}_k + \mathbf{H}_k (\alpha_k \mathbf{v}_k)$$

care înlocuită în (49) conduce la

$$\begin{aligned} \beta_k &= \frac{\mathbf{g}_{k+1}^T (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\mathbf{v}_k^T (\mathbf{g}_{k+1} - \mathbf{g}_k)} \\ &= \frac{\mathbf{g}_{k+1}^T (\mathbf{g}_{k+1} - \mathbf{g}_k)}{(-\mathbf{g}_k + \beta_{k-1} \mathbf{v}_{k-1})^T (\mathbf{g}_{k+1} - \mathbf{g}_k)}. \end{aligned} \quad (50)$$

Notes

Metoda gradientilor conjugați

Se poate arăta că șirul \mathbf{x}_k este astfel construit încât gradientul în \mathbf{x}_k și direcția \mathbf{v}_k satisfac în plus relațiile de ortogonalitate:

$$\mathbf{g}_{k+1}^T \mathbf{g}_j = 0, \quad \mathbf{v}_{k+1}^T \mathbf{g}_j = 0, \quad j \leq k, \quad (51)$$

Relații care înlocuite în (50) \Rightarrow

$$\beta_k = \frac{\mathbf{g}_{k+1}^T (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\mathbf{g}_k^T \mathbf{g}_k} = \frac{\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}}{\mathbf{g}_k^T \mathbf{g}_k}. \quad (52)$$

Notes

Metoda gradientilor conjugați

Oricare din cele două formule din relația (52) se pot folosi. Fiecare din ele este cunoscută sub un nume celebru, și anume:

$$\beta_k = \frac{\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}}{\mathbf{g}_k^T \mathbf{g}_k} \quad - \text{ formula Fletcher-Reeves (53)}$$

$$\beta_k = \frac{(\mathbf{g}_{k+1} - \mathbf{g}_k)^T \mathbf{g}_{k+1}}{\mathbf{g}_k^T \mathbf{g}_k} \quad - \text{ formula Polak-Ribiere. (54)}$$

Relațiile sunt echivalente într-o aritmetică exactă, dar numeric formula PR se preferă pentru că ea poate compensa micile "defecte" de ortogonalitate ale direcțiilor.

Notes

Algoritmul general al metodei GC

Varianta Polak-Ribiere


1. Alege \mathbf{x}_0
 $k = 0$
 Calculează $\mathbf{g}_0 = \nabla f(\mathbf{x}_0)$
 $\beta = 0$
2. **repetă**
 - 2.1. $\mathbf{v}_k = -\mathbf{g}_k + \beta \mathbf{v}_{k-1}$
 - 2.2. Minimizează $t(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{v}_k)$ în raport cu $\alpha \Rightarrow \alpha_k$
 - 2.3. $\mathbf{p}_k = \alpha_k \mathbf{v}_k$
 - 2.4. $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{p}_k$
 - 2.5. Calculează $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$
 - 2.6. $\beta = (\mathbf{g}_{k+1} - \mathbf{g}_k)^T * \mathbf{g}_{k+1} / (\mathbf{g}_k^T * \mathbf{g}_k)$
 - 2.7. $k = k + 1$

până când este îndeplinită condiția de oprire


Notes

Efortul de calcul

Pentru o funcție pătratică de n variabile se demonstrează că GC obține minimul după n pași (într-o aritmetică exactă). \Rightarrow este o metodă **semiiterativă**.



Metoda gradientului



Metoda gradientilor conjugați

GC este în general mai rapid convergentă decât metoda gradientului pentru funcții multidimensionale mai complexe (funcții neaparabolice).

Notes

Convergență

Def. Un algoritm are ordinul de convergență p dacă

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - x_{\min}\|}{\|x_k - x_{\min}\|^p} = C$$

unde C este o constantă, *rata de convergență*

- $p = 2$ - convergență **pătratică** (metoda Newton)
- $p = 1, C \neq 0, C < 1$ - convergență **liniară** (metoda gradientului)
- $p = 1, C = 0$ - convergență **superliniară** (metoda gradientilor conjugați după executarea a n pași)

Notes

Metode cvasi-Newton

Ideea:

- Simulează iterații de tip Newton, plasându-se între metoda gradientului și metoda Newton. Sunt metode de ordinul 1.
- Se lucrează cu **aproximări ale inversei matricei Hessian**, calculată cu ajutorul vectorului gradient evaluat în iterațiile precedente.
- Variante
 - mai simple - în care matricea rămâne constantă pe parcursul iterațiilor;
 - mai avansate - în care se construiesc aproximări din ce în ce mai bune - **algoritmi de metrică variabilă**

Notes

Metoda Newton modificată

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

Newton modificată

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{S}_k \mathbf{g}_k, \tag{55}$$

unde, \mathbf{S}_k este o matrice simetrică de dimensiune $n \times n$
 $\alpha_k \in \mathbb{R}_+$ determinat a.î. $t(\alpha) = f(\mathbf{x}_{k+1})$ să fie minimă³.

Obs

- ❶ dacă $\alpha_k \mathbf{S}_k = \mathbf{H}_k^{-1}$ - metoda Newton
- ❷ $\mathbf{S}_k = \mathbf{I}$ - metoda celei mai rapide coborâri

Strategia:

$$\mathbf{S}_k \approx \mathbf{H}_k^{-1}$$

Poate fi mai de succes decât Newton dacă nu există garanția că în punctul de minim matricea hessian e pozitiv definită.

³ Algoritmul dat de relația (55) este cunoscut și sub numele de *metoda gradientilor deviați*, deoarece vectorul direcție se obține printr-o transformare liniară a gradientului (prin înmulțirea lui cu matricea \mathbf{S}_k).

Notes

Construcția inversei H. Corecția de rangul unu.

Ideal: aproximarea \mathbf{S}_k să convergă către inversa matricei Hessian în punctul soluție și metoda să se comporte global ca metoda Newton.

$$f(\mathbf{x}) \approx f_k + (\mathbf{x} - \mathbf{x}_k)^T \mathbf{g}_k + \frac{1}{2}(\mathbf{x} - \mathbf{x}_k)^T \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k)$$

$$\nabla f(\mathbf{x}) \approx \mathbf{g}_k + \mathbf{H}_k (\mathbf{x} - \mathbf{x}_k)$$

⇒ evaluat în \mathbf{x}_{k+1}

$$\mathbf{g}_{k+1} \approx \mathbf{g}_k + \mathbf{H}_k (\mathbf{x}_{k+1} - \mathbf{x}_k). \tag{56}$$

Notăm:

$$\mathbf{p}_k = \mathbf{x}_{k+1} - \mathbf{x}_k, \tag{57}$$

$$\mathbf{q}_k = \mathbf{g}_{k+1} - \mathbf{g}_k. \tag{58}$$

Notes

Construcția inversei H. Corecția de rangul unu.

$$\Rightarrow \mathbf{q}_k = \mathbf{H} \mathbf{p}_k, \quad (59)$$

Evaluarea gradientului în două puncte dă informații despre matricea Hessian \mathbf{H} . Este natural să încercăm să construim aproximații succesive \mathbf{S}_k ale inversei matricei Hessian bazate pe datele obținute din primii k pași ai procesului de coborâre astfel încât, dacă \mathbf{H} ar fi constantă, aproximația să satisfacă relația (59), adică:

$$\mathbf{S}_{k+1} \mathbf{q}_i = \mathbf{p}_i, \quad 0 \leq i \leq k. \quad (60)$$

După n pași liniari independenți se obține $\mathbf{S}_n = \mathbf{H}^{-1}$. Deoarece \mathbf{H} și \mathbf{H}^{-1} sunt simetrice, este natural să se construiască o aproximație \mathbf{S}_k a lui \mathbf{H}^{-1} care este de asemenea simetrică. Se caută o schemă care păstrează simetria:

$$\mathbf{S}_{k+1} = \mathbf{S}_k + \mathbf{z}_k \mathbf{z}_k^T, \quad (61)$$

Notes

Construcția inversei H. Corecția de rangul unu.

Vectorul coloană \mathbf{z}_k definește o matrice care are rangul cel mult unu și care corectează aproximarea inversei matricei Hessian. Le vom alege astfel încât relația (60) să fie satisfăcută. Luând i egal cu k în relația (60) și folosind relația (61) se obține:

$$\mathbf{p}_k = \mathbf{S}_{k+1} \mathbf{q}_k = \mathbf{S}_k \mathbf{q}_k + \mathbf{z}_k \mathbf{z}_k^T \mathbf{q}_k, \quad (62)$$

de unde rezultă că:

$$\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k = \mathbf{z}_k \mathbf{z}_k^T \mathbf{q}_k, \quad (63)$$

$$(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)^T = \mathbf{q}_k^T \mathbf{z}_k \mathbf{z}_k^T, \quad (64)$$

și înmulțind aceste două relații rezultă că:

Notes

Construcția inversei H. Corecția de rangul unu.

$$\mathbf{z}_k \mathbf{z}_k^T = \frac{(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)^T}{(\mathbf{z}_k^T \mathbf{q}_k)^2}. \quad (65)$$

și, în final

$$\mathbf{S}_{k+1} = \mathbf{S}_k + \frac{(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)^T}{\mathbf{q}_k^T (\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)}. \quad (66)$$

Notes

Algoritmul metodei cvasi-Newton cu corecție de rang 1

1. Alege \mathbf{S}_0 simetrică și pozitiv definită
Alege \mathbf{x}_0
 $k = 0$
Calculează $\mathbf{g}_0 = \nabla f(\mathbf{x}_0)$
2. **repetă**
 - 2.1. $\mathbf{v}_k = -\mathbf{S}_k \mathbf{g}_k$
 - 2.2. Minimizează $t(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{v}_k)$ în raport cu $\alpha \geq 0 \Rightarrow \alpha_k$
 - 2.3. $\mathbf{p}_k = \alpha_k \mathbf{v}_k$
 - 2.4. $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{p}_k$
 - 2.5. Calculează $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$
 - 2.6. $\mathbf{q}_k = \mathbf{g}_{k+1} - \mathbf{g}_k$
 - 2.7. $\mathbf{S}_{k+1} = \mathbf{S}_k + \frac{(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)(\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)^T}{\mathbf{q}_k^T (\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k)}$
 - 2.8 $k = k + 1$

până când este îndeplinită condiția de oprire

Notes

Algoritmul metodei Davidon-Fletcher-Powell

1. Alege \mathbf{S}_0 simetrică și pozitiv definită
Alege \mathbf{x}_0
 $k = 0$
Calculează $\mathbf{g}_0 = \nabla f(\mathbf{x}_0)$
2. repetă
 - 2.1. $\mathbf{v}_k = -\mathbf{S}_k \mathbf{g}_k$
 - 2.2. Minimizează $t(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{v}_k)$ în raport cu $\alpha \geq 0 \Rightarrow \alpha_k$
 - 2.3. $\mathbf{p}_k = \alpha_k \mathbf{v}_k$
 - 2.4. $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{p}_k$
 - 2.5. Calculează $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$
 - 2.6. $\mathbf{q}_k = \mathbf{g}_{k+1} - \mathbf{g}_k$
 - 2.7. $\mathbf{S}_{k+1} = \mathbf{S}_k + \mathbf{p}_k \mathbf{p}_k^T / (\mathbf{p}_k^T \mathbf{q}_k) - \mathbf{S}_k \mathbf{q}_k \mathbf{q}_k^T \mathbf{S}_k / (\mathbf{q}_k^T \mathbf{S}_k \mathbf{q}_k)$
 - 2.8 $k = k + 1$

până când este îndeplinită condiția de oprire

Notes

Metoda Davidon-Fletcher-Powell

Se poate demonstra că

- Dacă \mathbf{S}_k este pozitiv definită, atunci \mathbf{S}_{k+1} este și ea pozitiv definită. Este interesant că această afirmație este adevărată chiar dacă α_k nu este un punct de minim pentru funcția $t(\alpha)$.
- Dacă f este o funcție pătratică, având deci o matrice Hessian constantă \mathbf{H} , atunci metoda Davidon-Fletcher-Powell generează direcții \mathbf{p}_k care sunt \mathbf{H} -ortogonale, iar după n pași $\mathbf{S}_n = \mathbf{H}^{-1}$. În acest caz, metoda face minimizări liniare succesive de-a lungul unor direcții conjugate. Mai mult, dacă aproximarea inițială \mathbf{S}_0 este luată matricea unitate, atunci metoda devine metoda gradientilor conjugați iar soluția se obține după n pași.

Notes

DFP vs BFGS

- Experimentele numerice au arătat că performanța formulei BFGS este superioară celei DFP, și de aceea ea este preferată.
- Atât DFP cât și BFGS folosesc o corecție de rangul doi care este construită cu ajutorul vectorilor \mathbf{p}_k și $\mathbf{S}_k \mathbf{q}_k$. Combinații ponderate ale acestor formule vor fi de aceea de același tip (simetrice, de rangul doi, și construite din \mathbf{p}_k și $\mathbf{S}_k \mathbf{q}_k$).

Această observație a condus în mod natural la considerarea unei familii întregi de metode, cunoscute sub numele de **metode de tip Broyden**, definite de relația

$$\mathbf{S}^\Phi = (1 - \Phi)\mathbf{S}^{\text{DFP}} + \Phi\mathbf{S}^{\text{BFGS}}, \quad (74)$$

unde Φ este un parametru care poate lua orice valoare reală.

Notes

Metrică variabilă sau gradienti conjugați?

- GC este un caz particular al metodelor de metrică variabilă (MV).
- Se folosește informația obținută din minimizări unidimensionale de-a lungul unor direcții succesive.
- Algoritmii sunt construiți astfel încât n minimizări liniare să conducă către minimul exact al unei funcții pătratice în n dimensiuni.
- Pentru funcții mai generale, nepătratice, direcțiile sunt întotdeauna coborâtoare, iar după n iterații convergența este superliniară.
- MV diferă de GC prin faptul că memorează și reactualizează informația acumulată.
În loc să memoreze un vector intermediar de dimensiune n , ele memorează o matrice de dimensiune $n \times n$. În general, pentru n moderat, acesta nu este un dezavantaj semnificativ.
- Există multe implementări sofisticate ale metodelor de MV, care minimizează eroarea de rotunjire sau tratează condiții mai speciale.

Notes

Aspecte avansate

- Metode de tip *trust region* (de exemplu Levenberg-Marquardt, etc)

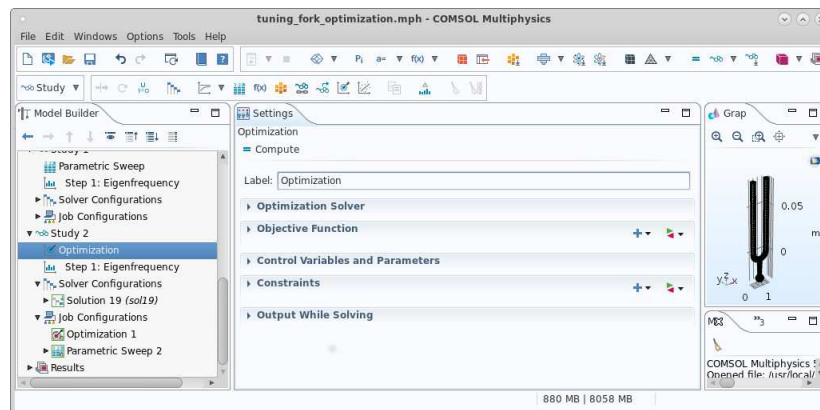
[Yuan15] Ya-xiang Yuan, Recent advances in trust region algorithms, Mathematical Programming 151(1), 2015, disponibila la

https://www.researchgate.net/publication/273908953_Recent_advances_in_trust_region_algorithms

- Tratarea restricțiilor

- SQP
- Interior point methods
- Method of moving asyptotes
- etc

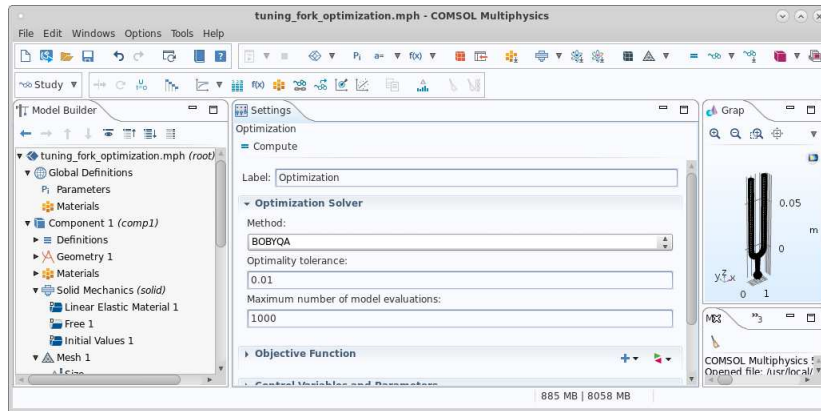
COMSOL - formularea problemei de optimizare



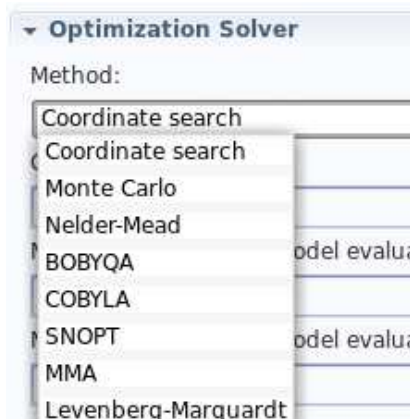
Notes

Notes

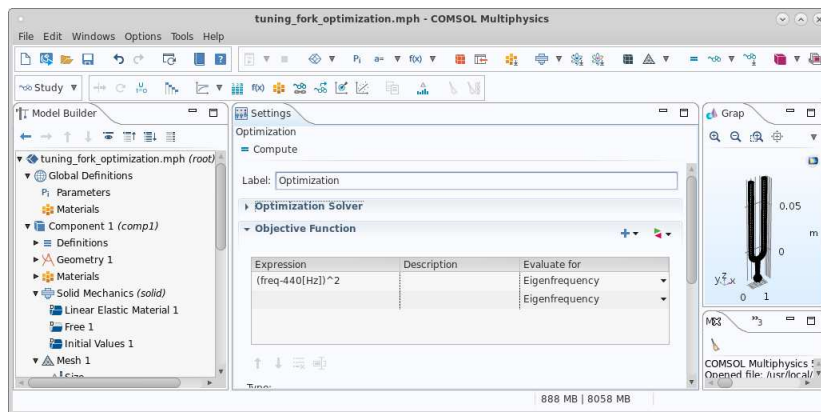
COMSOL - metode disponibile



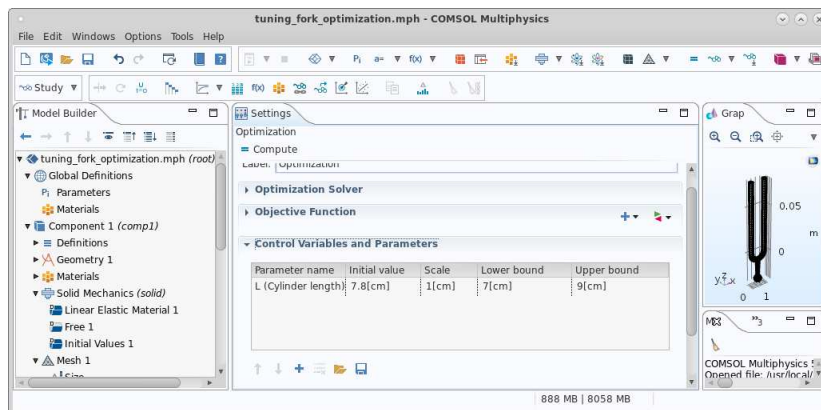
COMSOL - metode disponibile



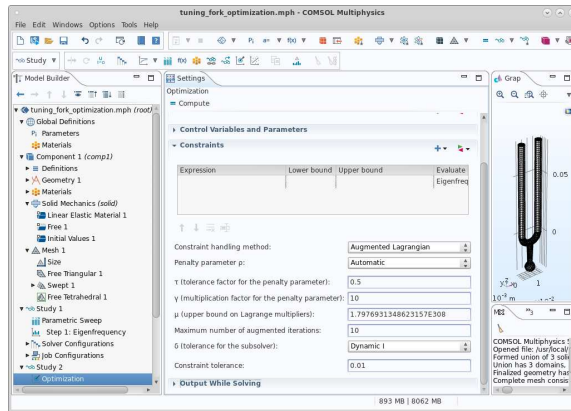
COMSOL - descrierea funcției obiectiv



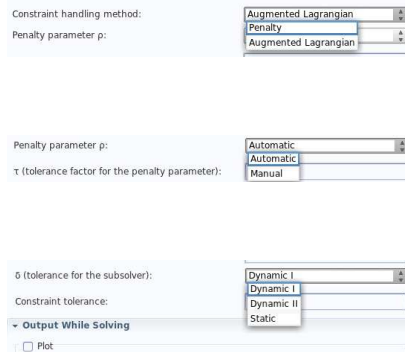
COMSOL - parametrii de optimizat și domeniile lor



COMSOL - alte restricții (info)



COMSOL - alte restricții (alegeri posibile)



Optimization toolbox

Fără restricții:

- Quasi-Newton
- Nelder-Mead:
- Regiunea de încredere (*trust region*) - utilă pentru probleme cu multe variabile, unde poate fi exploatată structura și raritatea.

Cu restricții

- Metode de punct interior;
- Programare pătratică secvențială (SQP);

Alte metode și detalii la <https://ch.mathworks.com/products/optimization.html>

Notes

Referințe

- [Ciuprina02] G.Ciuprina, D.Ioan, I.Munteanu, M.Rebican, R.Popa, Optimizarea numerica a dispozitivelor electromagnetice, Editura Printech, 2002.
disponibilă la <http://www.lmn.pub.ro/~gabriela/books/opt2002.pdf>
- [Cheney08] Ward Cheney and David Kincaid, *Numerical Mathematics and Computing*, Brooks/Cole publishing Company,2008. (Capitolul 16 - Minimization of functions)
- [Press02] W.H.Press, S.A.Teukolsky, W.T. Wetterling, B.P. Flannery, *Numerical Recipes in C*, 2002. (Capitolul 10)
Disponibilă la https://www2.units.it/ipi/students_area/imm2/files/Numerical_Recipes.pdf

Notes
