

# 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

# 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 lucrați
  - COMSOL
  - MATLAB

# 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:

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

Notații

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

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

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

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

# 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.

# 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

# 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.

# Metode de aproximare

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

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.

# 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.



# 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

# 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:

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

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

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

⇒

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

# 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

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

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

⇒

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

# 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.

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

dacă  $g(x) = f'(x)$ .

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

# 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).

# Metoda aproximării parabolice

 $\Rightarrow$ 

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

 $\Rightarrow$ 

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

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

$$g'(x) = 0 \Rightarrow$$

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

# 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.

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

dacă  $g(x) = f'(x)$ .

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

# Metoda aproximării parabolice

## c) Metoda interpolării parabolice

Condiții impuse:

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

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

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

⇒

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

$$q'(x) = 0 \Rightarrow x_{k+1}$$

Metode de ordin zero



# 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).

# Metoda aproximării parabolice - algoritm

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

stopval =  $1.e + 4$

fdvec(1) =  $f_{\text{der}}(x_1)$

$x(1) = x_1$

fdvec(2) =  $f_{\text{der}}(x_2)$

$x(2) = x_2$

$k = 2$

**cât timp** ( $k \leq \text{NMAX}$  și  $\text{stopval} \geq \text{EPS}$ )

$x(k+1) = x(k) - \text{fdvec}(k) * (x(k-1) - x(k)) / (\text{fdvec}(k-1) - \text{fdvec}(k))$

$\text{fdvec}(k+1) = f_{\text{der}}(x(k+1))$

$\text{stopval} = |\text{fdvec}(k+1)|$

$k = k + 1$

$x_{\min} = x(k)$

$f_{\min} = f(x(k))$

$n_{\text{iter}} = k - 2$

**retur**

# 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

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

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

## 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  $f$ :

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

$\Leftrightarrow$  vectorul gradient să fie nul.

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

### Condiția suficientă de minim

Matricea Hessian să fie pozitiv definită în punctul critic

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

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

# 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

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

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

⇒

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

# Metoda Newton

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_k^{-1} \mathbf{g}_k \quad (39)$$

Observații:

- Relația este similară cu cea de la cazul 1D;
- În practică nu se inversează matricea Hessian, ci se rezolvă

$$\mathbf{H}_k \mathbf{p}_k = -\mathbf{g}_k \quad \mathbf{p}_k \quad (40)$$

apoi se calculează

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{p}_k \quad (41)$$

- Dezavantaj: efort mare de calcul (o matrice Hessian la fiecare iterație și o rezolvare de sistem)

# Metoda gradientului

Am mai discutat această metodă și la rezolvarea sistemelor simetrice și pozitiv definite. Pe scurt:

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

Deoarece

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

Algoritmul se baza pe

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{r}^{(k)}$$

unde  $\mathbf{r}^{(k)} = -\nabla f(\mathbf{x}^{(k)})$

$\alpha_k$  se determina din  $t(\alpha_k) = f(\mathbf{x}^{(k+1)})$  min, de unde

$$\alpha_k = \frac{(\mathbf{r}^{(k)})^T (\mathbf{r}^{(k)})}{(\mathbf{r}^{(k)})^T \mathbf{A} \mathbf{r}^{(k)}}$$



# Metoda gradientului

Acum pornim direct cu optimizarea funcției neliniare  $f(\mathbf{x})$

Ideea:  $f(\mathbf{x}) \approx l(\mathbf{x})$  (aproximarea de ordinul 1)<sup>1</sup>

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

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.

---

<sup>1</sup>Notăm iterația ca indice.

# 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  $\alpha_k$  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.

## Căutarea valorii optime pentru $\alpha$

- 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  $\alpha_k$  s-ar putea elimina dacă se cunoaște Hessianul  $H$

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

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

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

# Căutarea valorii optime pentru $\alpha$



$\alpha_k$  - prin căutare liniară.

$\alpha'_k$  obținută cu (43)

Care este mai bună ?

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

# 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

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

# Algoritmul general al metodei gradientului

1. Alege  $\mathbf{x}_0$

$$k = 0$$

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

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  $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$

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

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

# Efortul de calcul

Efort de calcul mare - chiar și pentru o funcție pătratică



# Metoda gradientilor conjugați

Direcția de căutare depinde atât de direcția gradientului, cât și de direcția de căutare anterioară<sup>2</sup>

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

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):

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

---

<sup>2</sup>Revedeți și prezentarea de la sisteme algebrice liniare.



# Metoda gradientilor conjugați

Determinăm  $\beta$  înlocuind (47) în (48).

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

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

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

$\Rightarrow$

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

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

# 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  $\mathbf{x} = \mathbf{x}_{k+1}$

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

care înlocuită în (49) conduce la

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

# 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)  $\Rightarrow$

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

# 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.

# 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. Minimizați  $t(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{v}_k)$  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

# Efortul de calcul

Pentru o funcție pătratică de  $n$  variabile se demonstrează că GC obține minimumul 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 neparabolice).

# Convergență

Def. Un algoritm are ordinul de convergență  $p$  dacă

$$\lim_{k \rightarrow \infty} \frac{\|\mathbf{x}_{k+1} - \mathbf{x}_{\min}\|}{\|\mathbf{x}_k - \mathbf{x}_{\min}\|^p} = C$$

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)

# 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**



# Metoda Newton modificată

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

Newton modificată

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

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 minimă<sup>3</sup>.

Obs

- 1 dacă  $\alpha_k \mathbf{S}_k = \mathbf{H}_k^{-1}$  - metoda Newton
- 2  $\mathbf{S}_k = \mathbf{I}$  - 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.

<sup>3</sup> 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  $\mathbf{S}_k$ ).

# 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  $\mathbf{x}_{k+1}$

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

Notăm:

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

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

# Construcția inversei $\mathbf{H}$ . 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:

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

# 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:

# 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

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

# 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  $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_k)$

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

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

2.8  $k = k + 1$

**până când** este îndeplinită condiția de oprire

# Algoritmul metodei cvasi-Newton cu corecție de rang 1

Dificultăți:

- $\mathbf{S}_{k+1}$  calculată cu formula (66) rămâne pozitiv definită numai dacă  $\mathbf{q}_k^T (\mathbf{p}_k - \mathbf{S}_k \mathbf{q}_k) > 0$ , condiție care nu poate fi garantată.
- Chiar dacă  $\mathbf{S}_{k+1}$  este pozitivă, în cazul în care ea este mică apar dificultăți numerice.

# Metoda Davidon-Fletcher-Powell

- Are o proprietate uimitoare: pentru o funcție obiectiv pătratică generează simultan direcțiile din metoda gradientilor conjugați și construiește inversa matricei Hessian.
- La fiecare pas aproximația inversei matricei Hessian este corectată prin intermediul a două matrice simetrice de rangul unu, și de aceea această schemă este adesea numită **procedura de corecție de rangul doi**.

Formula propusă pentru calculul aproximării inversei matricei Hessian:

$$\mathbf{S}_{k+1} = \mathbf{S}_k + \frac{\mathbf{p}_k \mathbf{p}_k^T}{\mathbf{p}_k^T \mathbf{q}_k} - \frac{\mathbf{S}_k \mathbf{q}_k \mathbf{q}_k^T \mathbf{S}_k}{\mathbf{q}_k^T \mathbf{S}_k \mathbf{q}_k}. \quad (67)$$



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

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

# 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  $\alpha_k$  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.

# Metoda Broyden-Fletcher-Goldfarb-Shanno

La DFP, formula pentru calculul matricei  $\mathbf{S}_{k+1}$  se bazează pe

$$\mathbf{S}_{k+1} \mathbf{q}_i = \mathbf{p}_i, \quad 0 \leq i \leq k, \quad (68)$$

care a fost dedusă din

$$\mathbf{q}_i = \mathbf{H} \mathbf{p}_i, \quad 0 \leq i \leq k, \quad (69)$$

relație care este adevărată dacă funcția  $f$  este pătratică.

Altă idee: a folosi aproximații chiar ale matricei Hessian și nu ale inversei ei.

- Notăm aproximațiile lui  $\mathbf{H}$  cu  $\mathbf{T}_k$
- Vom căuta în mod analog să avem satisfăcute relațiile:

$$\mathbf{q}_i = \mathbf{T}_{k+1} \mathbf{p}_i, \quad 0 \leq i \leq k. \quad (70)$$

# Metoda Broyden-Fletcher-Goldfarb-Shanno

Se obține:

Corecția de rangul unu:

$$\mathbf{T}_{k+1} = \mathbf{T}_k + \frac{(\mathbf{q}_k - \mathbf{T}_k \mathbf{p}_k)(\mathbf{q}_k - \mathbf{T}_k \mathbf{p}_k)^T}{\mathbf{p}_k^T (\mathbf{q}_k - \mathbf{T}_k \mathbf{p}_k)}. \quad (71)$$

Și corecția de rangul doi (BFGS)

$$\mathbf{T}_{k+1} = \mathbf{T}_k + \frac{\mathbf{q}_k \mathbf{q}_k^T}{\mathbf{q}_k^T \mathbf{p}_k} - \frac{\mathbf{T}_k \mathbf{p}_k \mathbf{p}_k^T \mathbf{T}_k}{\mathbf{p}_k^T \mathbf{T}_k \mathbf{p}_k} \quad (72)$$

de unde

$$\mathbf{S}_{k+1}^{\text{BFGS}} = \mathbf{S}_k + \left( \frac{1 + \mathbf{q}_k^T \mathbf{S}_k \mathbf{q}_k}{\mathbf{q}_k^T \mathbf{p}_k} \right) \frac{\mathbf{p}_k \mathbf{p}_k^T}{\mathbf{p}_k^T \mathbf{q}_k} - \frac{\mathbf{p}_k \mathbf{q}_k^T \mathbf{S}_k + \mathbf{S}_k \mathbf{q}_k \mathbf{p}_k^T}{\mathbf{q}_k^T \mathbf{p}_k} \quad (73)$$

În algoritm DFP, se schimbă pasul 2.7

# 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  $\Phi$  este un parametru care poate lua orice valoare reală.

# 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.

# Aspecte avansate

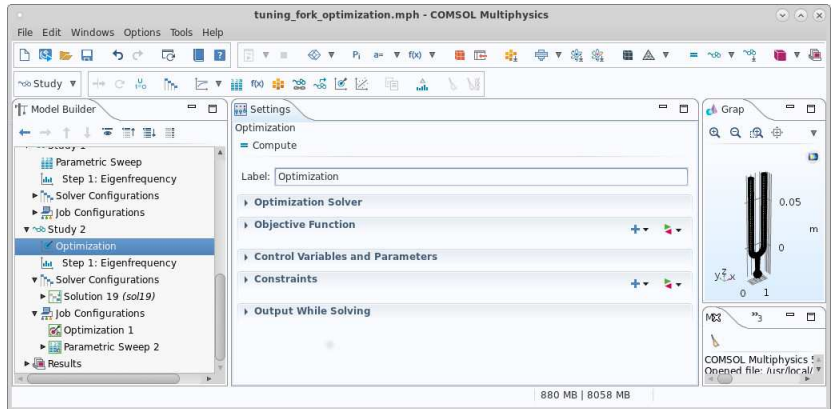
- Metode de tip *trust region* (de exemplu Levenberg-Marquardt, etc)

[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](https://www.researchgate.net/publication/273908953_Recent_advances_in_trust_region_algorithms)

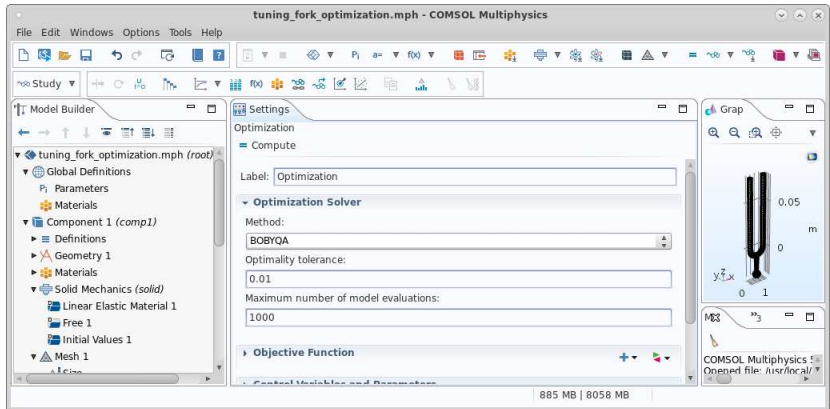
- Tratarea restricțiilor
  - SQP
  - Interior point methods
  - Method of moving asymptotes
  - etc

## COMSOL - formularea problemei de optimizare

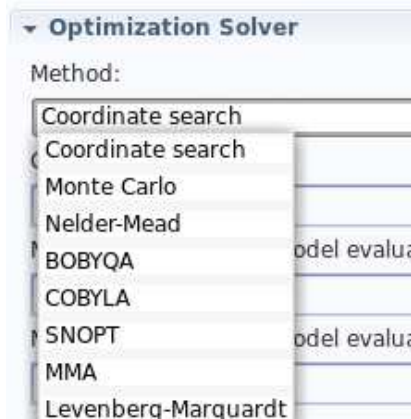




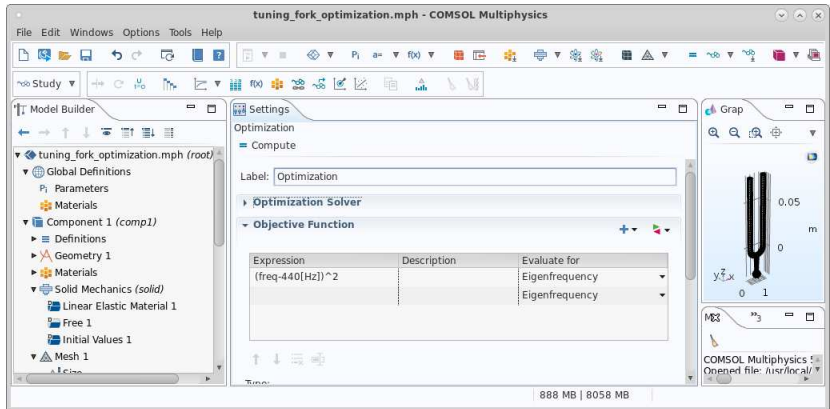
# COMSOL - metode disponibile



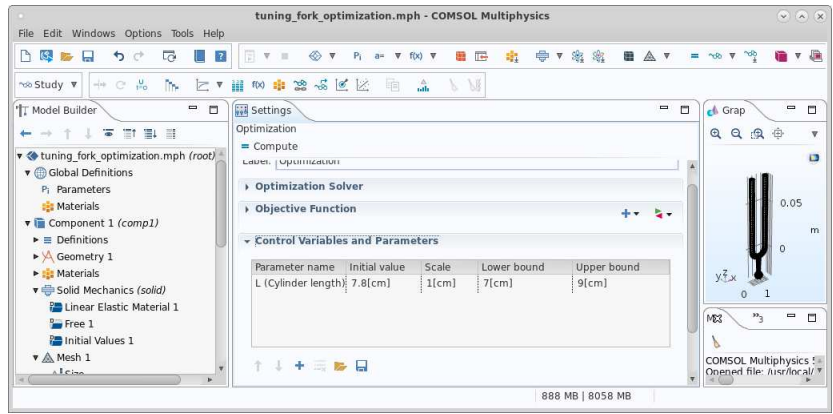
## COMSOL - metode disponibile



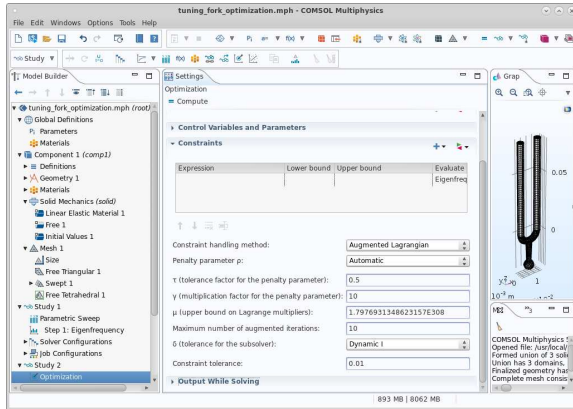
# COMSOL - descrierea funcției obiectiv



# COMSOL - parametri de optimizat și domenii lor



## COMSOL - alte restricții (info)



## COMSOL - alte restricții (alegeri posibile)

Constraint handling method:

Penalty parameter  $p$ :

Penalty parameter  $p$ :

$\tau$  (tolerance factor for the penalty parameter):

$\delta$  (tolerance for the subsolver):

Constraint tolerance:

**Output While Solving**

Plot

## 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>

# Referințe

- [Ciuprina02] G.Ciuprina, D.Ioan, I.Munteanu, M.Rebican, R.Popa, Optimizarea numerica a dispozitivelor electromagnetice, Editura Printech, 2002.
- [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 Recipies in C*, 2002. (Capitolul 10)

disponibilă la <http://www.lmn.pub.ro/~gabriela/books/opt2002.pdf>

Disponibilă la [https://www2.units.it/ipl/students\\_area/imm2/files/Numerical\\_Recipes.pdf](https://www2.units.it/ipl/students_area/imm2/files/Numerical_Recipes.pdf)