

# Algebră Liniară și Optimizare

## Curs 8

Conf. dr. Anca Ignat

Conf. dr. Corina Forăscu

April 21, 2026

# Optimizare numerică

Probleme de minimizare

$$\min \{ f(x) ; x \in D \}, \quad D \subseteq \mathbb{R}^n, \quad f : \mathbb{R}^n \longrightarrow \mathbb{R}$$

O problemă de maximizare se poate reduce la una de minimizare astfel:

$$\max \{ f(x) ; x \in D \} = - \min \{ -f(x) ; x \in D \}.$$

# Tipuri de probleme de optimizare

- liniară sau neliniară - funcția  $f$  este liniară sau neliniară
- pătratică - funcția  $f$  este pătratică
- convexă - funcția  $f$  este convexă
- fără restricții -  $D \subseteq \mathbb{R}^n$
- cu restricții -  $D = \{x \in \mathbb{R}^n ; g(x) \leq 0\}$
- continuă -  $x$  ia valori reale,  $D \subseteq \mathbb{R}^n$
- discretă -  $x$  ia valori discrete,  $D$  mulțime de valori discrete
- în numere întregi -  $D \subseteq \mathbb{Z}^n$
- mixtă - unele componente ale vectorului  $x$  sunt discrete și celelalte sunt continui
- ...

# Optimizare - Definiții

Considerăm problema de minimizare fără restricții:

$$\min \{ f(x) ; x \in \mathbb{R}^n \} \quad f : \mathbb{R}^n \longrightarrow \mathbb{R}$$

Un punct  $x^* \in \mathbb{R}^n$  se numește **punct de minim global** pentru funcția  $f$  dacă  $f(x^*) \leq f(x)$ ,  $\forall x \in \mathbb{R}^n$ .

Un punct  $x^* \in \mathbb{R}^n$  se numește **punct de minim local** pentru funcția  $f$  dacă există o vecinătate  $V$  a punctului  $x^*$  astfel încât  $f(x^*) \leq f(x)$ ,  $\forall x \in V$ .

Un punct  $x^* \in \mathbb{R}^n$  se numește **punct de minim strict local** pentru funcția  $f$  dacă există o vecinătate  $V$  a punctului  $x^*$  astfel încât  $f(x^*) < f(x)$ ,  $\forall x \in V, x \neq x^*$ .

$$V = S(x^*, r) = \{ x \in \mathbb{R}^n ; \|x - x^*\| \leq r \}$$

# Optimizare - Definiții

Dacă funcția  $f \in C^1(\mathbb{R}^n)$ , se numește **gradient** al funcției  $f$  în punctul  $x$ , vectorul:

$$\nabla f(x) = \left( \frac{\partial f}{\partial x_1}(x), \frac{\partial f}{\partial x_2}(x), \dots, \frac{\partial f}{\partial x_n}(x) \right)^T$$

Dacă funcția  $f \in C^2(\mathbb{R}^n)$ , se numește **matrice Hessiană** a funcției  $f$  în punctul  $x$ , matricea:

$$H_f(x) = \nabla^2 f(x) = \left( \frac{\partial^2 f}{\partial x_i \partial x_j}(x) \right)_{i,j=1,\dots,n} \in \mathbb{R}^{n \times n}$$

# Matricea Hessiană

$$H_f(x) = \nabla^2 f(x) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2}(x) & \frac{\partial^2 f}{\partial x_1 \partial x_2}(x) & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n}(x) \\ \frac{\partial^2 f}{\partial x_2 \partial x_1}(x) & \frac{\partial^2 f}{\partial x_2^2}(x) & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n}(x) \\ & & \vdots & \\ \frac{\partial^2 f}{\partial x_n \partial x_1}(x) & \frac{\partial^2 f}{\partial x_n \partial x_2}(x) & \cdots & \frac{\partial^2 f}{\partial x_n^2}(x) \end{pmatrix}$$

# Dezvoltare în serie Taylor de ordinul 1

$$f \in C^2(\mathbb{R}^n) \quad , \quad a = (a_1, a_2, \dots, a_n)^T \in \mathbb{R}^n$$

$$\begin{aligned} f(x) &= f(a) + \sum_{i=1}^n \frac{\partial f}{\partial x_i}(a)(x_i - a_i) + R(\|x - a\|^2) \\ &= f(a) + \nabla f(a)^T(x - a) + R(\|x - a\|^2) \end{aligned}$$

## Dezvoltare în serie Taylor de ordinul al 2-lea

$$f \in C^2(\mathbb{R}^n) \quad , \quad a = (a_1, a_2, \dots, a_n)^T \in \mathbb{R}^n$$

$$\begin{aligned} f(x) &= f(a) + \sum_{i=1}^n \frac{\partial f}{\partial x_i}(a)(x_i - a_i) + \\ &\quad + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \frac{\partial^2 f}{\partial x_i \partial x_j}(a)(x_i - a_i)(x_j - a_j) + \bar{R}(\|x - a\|^3) \\ &= f(a) + \nabla f(a)^T(x - a) + \frac{1}{2}(x - a)^T H_f(a)(x - a) + \bar{R}(\|x - a\|^3) \end{aligned}$$

# Optimizare - condiții necesare de optim de ordinul 1

## Teorema 1

Fie  $f \in C^1(\mathbb{R}^n)$  și  $x^* \in \mathbb{R}^n$  un punct de minim local pentru funcția  $f$ . Atunci  $\nabla f(x^*) = 0$ .

Un punct  $x^* \in \mathbb{R}^n$  pentru care  $\nabla f(x^*) = 0$  se numește **punct staționar/critic** pentru funcția  $f$ .

Teorema de mai sus spune că orice punct de minim local pentru funcția  $f$  trebuie să fie punct staționar. Punctele de minim local pot fi căutate printre soluțiile sistemului nelinier de ecuații  $\nabla f(x) = 0$ .

# Optimizare - condiții necesare de optim de ordinul al 2-lea

## Teorema 2

Fie  $f \in C^2(\mathbb{R}^n)$  și  $x^* \in \mathbb{R}^n$  un punct de minim local pentru funcția  $f$ . Atunci  $\nabla f(x^*) = 0$  și matricea Hessiană  $H_f(x^*)$  este pozitiv semidefinită.

O matrice  $A \in \mathbb{R}^{n \times n}$  se numește **pozitiv definită** dacă:

$$(Ax, x)_{\mathbb{R}^n} > 0 \quad , \quad \forall x \in \mathbb{R}^n, x \neq 0$$

O matrice  $A \in \mathbb{R}^{n \times n}$  se numește **pozitiv semidefinită** dacă:

$$(Ax, x)_{\mathbb{R}^n} \geq 0 \quad , \quad \forall x \in \mathbb{R}^n$$

# Optimizare - condiții suficiente de optim de ordinul al 2-lea

## Teorema 3

Fie  $f \in C^2(\mathbb{R}^n)$ ,  $x^* \in \mathbb{R}^n$  un punct staționar,  $\nabla f(x^*) = 0$  pentru care matricea Hessiană  $H_f(x^*)$  este pozitiv definită. Atunci  $x^*$  este punct de minim strict local pentru funcția  $f$ .

# Optimizare - funcții convexe

O funcție  $f : \mathbb{R}^n \longrightarrow \mathbb{R}$  se numește **funcție convexă** dacă:

$$f(ax_1+(1-a)x_2) \leq af(x_1)+(1-a)f(x_2), \forall x_1, x_2 \in \mathbb{R}^n, \forall a \in [0, 1]$$

## Teorema 4

Daca funcția  $f : \mathbb{R}^n \longrightarrow \mathbb{R}$  este convexă atunci orice punct de minim local este punct de minim global. Dacă, în plus,  $f \in C^1(\mathbb{R}^n)$  atunci orice punct staționar ( $\nabla f(x^*) = 0$ ) este punct de minim global.

# Optimizare - Metode de descreștere

Se numește **direcție de descreștere** a funcției  $f$  în punctul  $x$ , un vector  $d \in \mathbb{R}^n$  pentru care:

$$f(x + \alpha d) \leq f(x) \quad , \quad \forall \alpha \in [0, \bar{\alpha}).$$

## Teorema 5

Fie  $f \in C^1(\mathbb{R}^n)$ . Un vector  $d \in \mathbb{R}^n$  este direcție de descreștere pentru funcția  $f$  în punctul  $x$  dacă și numai dacă:

$$\nabla f(x)^T d = (d, \nabla f(x))_{\mathbb{R}^n} < 0.$$

# Algoritm de optimizare

## *Metodă de descreștere*

1. alege  $x \in \mathbb{R}^n$
2. do
  - ▶ găsește o direcție de descreștere  $d$  a funcției  $f$  în  $x$ ;
  - ▶ găsește  $\tilde{\alpha} > 0$  astfel ca:

$$f(x + \tilde{\alpha} d) = \min \{f(x + \alpha d) ; \alpha \in [0, \tilde{\alpha}]\}$$

(ajustarea pasului -line search)

- ▶  $x = x + \tilde{\alpha} d$

while (nu am găsit soluția);

## Ajustarea pasului (line search)

Pentru găsirea lui  $\tilde{a}$ , avem de rezolvat o problemă de minimizare unidimensională:

$$\min \{ g(a) ; a \in [b, c] \}. \quad (1)$$

Pentru rezolvarea acestei probleme, de obicei, se folosesc algoritmi care aproximează soluția ecuației neliniare  $g'(a) = 0$ . Se construiesc șiruri de vectori  $(a_k)$ , care, în anumite cazuri, converg la soluția problemei  $g'(a) = 0$ . Pentru ca soluția găsită să fie și soluția problemei (1), este necesar ca  $g''(a^*) \geq 0$ .

# Metoda Newton

Fie  $a_k$  aproximarea curentă soluției problemei de minimizare (1). Folosim dezvoltarea în serie Taylor a funcției  $g$ :

$$g(a) = g(a_k) + g'(a_k)(a - a_k) + \frac{1}{2!}g''(a_k)(a - a_k)^2 + \frac{1}{3!}g'''(a_k)(a - a_k)^3.$$

Fie funcția  $q$  definită de:

$$q(a) = g(a_k) + g'(a_k)(a - a_k) + \frac{1}{2}g''(a_k)(a - a_k)^2. \quad (2)$$

# Metoda Newton

Pentru valori ale lui  $a$  în apropiere lui  $a_k$  putem presupune că funcția  $q$  aproximează funcția  $g$ ,  $g(a) \approx q(a)$ . Pentru a afla următorul element din șir,  $a_{k+1}$ , vom minimiza funcția  $q$  (în locul funcției  $g$ ).

Calculăm următorul element din șir,  $a_{k+1}$ , ca soluție a problemei de minimizare:

$$q(a_{k+1}) = \min \{ q(a) ; a \in [b, c] \}.$$

Funcția  $q$  este un polinom de grad 2 în necunoscuta  $a$ , de unde vom obține următoarea formulă pentru  $a_{k+1}$ :

$$a_{k+1} = a_k - \frac{g'(a_k)}{g''(a_k)}, \quad k = 0, 1, 2, \dots$$

Primul element al șirului,  $a_0$  se alege la întâmplare.

# Metoda secantei

Dacă în relația (2), se face următoarea aproximare:

$$g''(a_k) \approx \frac{g'(a_k) - g'(a_{k-1})}{a_k - a_{k-1}}$$

obținem următoarea metodă de aproximare, numită **metoda secantei**:

$$a_{k+1} = a_k - g'(a_k) \frac{a_k - a_{k-1}}{g'(a_k) - g'(a_{k-1})}, \quad k = 0, 1, \dots$$

Pentru a construi șirul  $a_k$ , trebuie precizate primele două elemente din șir,  $a_0$  și  $a_1$ .

# Aproximare spline cubică

Pentru a construi elementul  $a_{k+1}$  al șirului, vom folosi elementele  $a_{k-1}, a_k$  și valorile  $g(a_{k-1}), g(a_k), g'(a_{k-1}), g'(a_k)$ . Aproximăm funcția  $g$  cu un polinom de gradul al 3-lea:

$$g(a) \approx q(a) = c_0 a^3 + c_1 a^2 + c_2 a + c_3.$$

Funcția  $q$ , respectiv constantele  $c_i, i = 0, \dots, 3$ , se calculează astfel ca:

$$\begin{aligned} q(a_{k-1}) &= g(a_{k-1}) & , & & q(a_k) &= g(a_k) \\ q'(a_{k-1}) &= g'(a_{k-1}) & , & & q'(a_k) &= g'(a_k) \end{aligned}$$

# Aproximare spline cubică

Elementul  $a_{k+1}$  este punctul de minim al funcției  $q$  și se calculează folosind următoarele formule:

$$a_{k+1} = a_k - (a_k - a_{k-1}) \frac{g'(a_k) + u_2 - u_1}{g'(a_k) - g'(a_{k-1}) + 2u_2}$$

$$u_1 = g'(a_{k-1}) + g'(a_k) - 3 \frac{g(a_k) - g(a_{k-1})}{a_k - a_{k-1}}$$

$$u_2 = \sqrt{u_1^2 - g'(a_{k-1})g'(a_k)}$$

# Ajustarea inexactă a pasului

$$f(x + \tilde{\alpha} d) \approx \min \{ f(x + \alpha d) ; \alpha \in [0, \bar{\alpha}) \}.$$

- nu se obține  $\tilde{\alpha}$  optimal;
- pentru reducerea timpului de lucru, procedeul de calcul a punctului de optim se oprește înainte de a ajunge la soluție, în funcție de anumite criterii/teste de oprire.

# Ajustarea inexactă a pasului

## Regula lui Armijo

$$g(a) = f(x_k + a d_k) \quad , \quad \bar{g}(a) = g(0) + \epsilon g'(0) \quad , \quad \epsilon \in (0, 1).$$

O valoare  $\bar{a}$  este acceptabilă după regula lui Armijo dacă:

1.  $g(\bar{a}) \leq \bar{g}(\bar{a})$
2.  $g(\sigma \bar{a}) \geq \bar{g}(\sigma \bar{a})$

$\sigma = 2$  sau  $10$ ,  $\epsilon = 0.2$ .

# Ajustarea inexactă a pasului - regula Armijo

$k = 0;$

se alege  $a_0;$

while (  $g(a_k) > \bar{g}(a_k)$  )

- $a_k = \frac{1}{\sigma} a_k$
- $k = k + 1;$

# Ajustarea inexactă a pasului

## Testul Goldstein

Dat  $\epsilon \in (0, 2)$ ,  $\bar{\alpha}$  este considerat acceptabil dacă:

$$g(\bar{\alpha}) \leq \quad \text{și} \quad g(\bar{\alpha}) > g(0) + (1 - \epsilon)g'(0)$$

Alternativ, valoarea  $\bar{\alpha}$  este acceptată dacă:

$$\epsilon \leq \frac{f(x_{k+1}) - f(x_k)}{\bar{\alpha} \nabla f(x_k)^T d_k} \leq 1 - \epsilon$$

# Ajustarea inexactă a pasului


## Testul Wolfe

Pentru  $\epsilon \in (0, 2)$ , o valoare  $\bar{\alpha}$  îndeplinește condiția de acceptare dacă:


$$g(\bar{\alpha}) \leq \bar{g}(\bar{\alpha}) = g(0) + \epsilon g'(0)$$

$$g'(\bar{\alpha}) \geq (1 - \epsilon)g'(0)$$


# Ajustarea inexactă a pasului



(a) Armijo rule



(b) Goldstein test



(c) Wolfe test

# Optimizare - forme pătratice

Fie  $A \in \mathbb{R}^{n \times n}$  o matrice simetrică și pozitiv (semi)definită,  $b \in \mathbb{R}^n$ . Se numește **formă pătratică** o funcție  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  definită astfel:

$$\begin{aligned} f(x) &= \frac{1}{2}(Ax, x)_{\mathbb{R}^n} - (b, x)_{\mathbb{R}^n} + c \\ &= \frac{1}{2}x^T Ax - x^T b + c \quad , \quad c \in \mathbb{R} \end{aligned}$$

# Optimizare - forme pătratice

Gradientul și matricea Hessiană a unei forme pătratice sunt:

$$\nabla f(x) = Ax - b \quad , \quad H_f(x) = \nabla^2 f(x) = A.$$

Dacă matricea  $A$  este pozitiv definită, avem  $\det A \neq 0$  și funcția  $f$  este strict convexă. Orice punct de minim local este punct de minim global.

Problema de minimizare:

$$f(x^*) = \min \{ f(x) ; x \in \mathbb{R}^n \}$$

are un punct de minim unic,  $x^* \in \mathbb{R}^n$ . Acest punct unic de minim este soluția sistemului liniar:

$$Ax = b \quad , \quad x^* = A^{-1}b$$

# Metoda pantei maxime (steepest descent)

Considerăm problema de minimizare pentru funcția  
 $f : \mathbb{R}^n \rightarrow \mathbb{R}$ :

$$\min \{f(x); x \in \mathbb{R}^n \}.$$

Soluția acestei probleme poate fi aproximată folosind un șir construit cu o metodă de descreștere:

$$x_0 \text{ dat } , \quad x_{k+1} = x_k + \alpha_k d_k , \quad k = 0, 1, \dots$$

unde  $d_k$  este o direcție de descreștere a funcției  $f$  în  $x_k$  iar  $\alpha_k > 0$  este soluția problemei de minimizare:

$$f(x_k + \alpha_k d_k) = \min \{f(x_k + \alpha d_k); \alpha \in [0, \bar{\alpha}) \}.$$

**Metoda pantei maxime** consideră ca direcția de descreștere:

$$d_k = -\nabla f(x_k).$$

# Metoda pantei maxime - forme pătratică

$$g(x) = Ax - b$$

$$x_{k+1} = x_k - \alpha_k g_k \quad , \quad g_k = g(x_k) = Ax_k - b.$$

$$\alpha_k = \arg \min \{ f(x_k - \alpha g_k) ; \alpha \in [0, \bar{\alpha}) \}$$

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

$$= \frac{1}{2}(g_k^T A g_k) \alpha^2 - (g_k^T A x_k - g_k^T b) \alpha + f(x_k)$$

$$= \frac{1}{2}(g_k^T A g_k) \alpha^2 - (g_k^T g_k) \alpha + f(x_k)$$

# Metoda pantei maxime - forme pătratică

$f(x_k - \alpha g_k)$  - funcție polinomială de gradul 2 în  $\alpha$ ,  
coeficientul lui  $\alpha^2$  este pozitiv,  $g_k^T A g_k > 0$  ( $A$  este pozitiv  
definită). Punctul de minim al lui  $f(x_k - \alpha g_k)$  este:

$$\alpha_{\min} = \alpha_k = \frac{g_k^T g_k}{g_k^T A g_k}$$

$$\alpha_k = \frac{\|g_k\|_2^2}{(A g_k, g_k)_{\mathbb{R}^n}}$$

# Metoda pantei maxime - forme pătratică

$x_0$  - dat

$$g_k = Ax_k - b \quad , \quad \alpha_k = \frac{g_k^T g_k}{g_k^T A g_k}$$

$$x_{k+1} = x_k - \alpha_k g_k \quad , \quad k = 0, 1, \dots$$

# Metoda pantei maxime - $f$ oarecare

$x_0$  - dat

$$g_k = \nabla f(x_k)$$

$$\alpha_k = \arg \min \{f(x_k - \alpha g_k); \alpha \in [0, \bar{\alpha})\}$$

$$x_{k+1} = x_k - \alpha_k g_k \quad , \quad k = 0, 1, \dots$$

# Metoda pantei maxime

Pentru  $f$  formă pătratică:

$$E(x) = \frac{1}{2}(x - x^*)^T A(x - x^*) = f(x) + \frac{1}{2}(x^*)^T Ax^*$$

$$\nabla E(x) = \nabla f(x) = g(x)$$

Pentru forme pătratice, șirul construit cu metoda pantei maxime satisface relația:

$$E(x_{k+1}) = \left[ 1 - \frac{(g_k^T g_k)^2}{\left(g_k^T A g_k\right) \left(g_k^T A^{-1} g_k\right)} \right] E(x_k)$$

# Inegalitatea lui Kantorovici

Pentru  $A \in \mathbb{R}^{n \times n}$ , simetrică și pozitiv definită are loc inegalitatea:

$$\frac{(x^T x)^2}{(x^T A x)(x^T A^{-1} g_x)} \geq \frac{4cC}{(c+C)^2}$$

unde  $c$  este cea mai mică valoare proprie a matricei  $A$  și  $C$  este cea mai mare valoare proprie

# Metoda pantei maxime - convergența

## Teorema 6 (cazul pătratic)

Fie  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  o formă pătratică. Pentru orice iterație inițială  $x_0$ , șirul construit cu metoda pantei maxime converge la  $x^*$  unicul punct de minim al funcției  $f$ ,  $x_k \rightarrow x^*, k \rightarrow \infty$ . Are loc următoarea relație:

$$E(x_{k+1}) \leq \left( \frac{C - c}{C + c} \right)^2 E(x_k).$$

# Metoda pantei maxime - convergența

## Teorema 7 (cazul general)

Fie funcția  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $f \in C^2(\mathbb{R}^n)$ . Presupunem că  $x^* \in \mathbb{R}^n$  este un punct de minim local al funcției  $f$ . Presupunem că matricea Hessiană  $H_f(x^*) = \nabla^2 f(x^*)$  are  $c > 0$  cea mai mică valoare proprie și  $C > 0$  cea mai mare valoare proprie (matricea Hessiană  $H_f(x^*)$  este pozitiv definită). Dacă șirul  $(x_k)$  construit cu metoda pantei maxime converge la  $x^*$ ,  $x_k \rightarrow x^*$ ,  $k \rightarrow \infty$  atunci are loc următoarea relație:

$$f(x_{k+1}) - f(x^*) \leq \left( \frac{C - c}{C + c} \right)^2 [f(x_k) - f(x^*)].$$

# Metoda gradientului descendent

$x_0$  – dat

$$x_{k+1} = x_k - \eta \nabla f(x_k) \quad , \quad k = 0, 1, \dots$$

$\eta$  este o valoare mică, pozitivă ( $\eta = 10^{-1}, 10^{-2}, \dots$ ), care poartă numele de **rată de învățare**.

Pentru probleme de maximizare metoda se numește a gradientului ascendent și are forma:

$x_0$  – dat

$$x_{k+1} = x_k + \eta \nabla f(x_k) \quad , \quad k = 0, 1, \dots$$

# Metoda Newton

Fie  $x_k$  iterația curentă a șirului care aproximează soluția problemei de minimizare:

$$\min \{f(x); x \in \mathbb{R}^n \}.$$

Scriem dezvoltarea în serie Taylor de ordinul 2 în jurul punctului  $x_k$ :

$$f(x) = g(y) + R(\|x - x_k\|^3) \quad , \quad y = x - x_k$$

$$g(y) = f(x_k) + \nabla f(x_k)^T (x - x_k) + \frac{1}{2} (x - x_k)^T \nabla^2 f(x_k) (x - x_k)$$

$$= \frac{1}{2} y^T A y - y^T b + c \quad ,$$

$$A = \nabla^2 f(x_k) \quad , \quad b = -\nabla f(x_k) \quad , \quad c = f(x_k)$$

# Metoda Newton

Problema de minimizare:

$$\min \{ g(y) ; y \in \mathbb{R}^n \}$$

are un unic punct de minim  $y^*$ , dacă matricea  $A$  este simetrică și pozitiv definită. Acest punct de minim este soluția sistemului liniar  $Ay = b$ :

$$y^* = A^{-1}b = [\nabla^2 f(x_k)]^{-1} \nabla f(x_k)$$

Șirul construit cu **metoda Newton** are următoarea formulă de recurență:

$$x_{k+1} = x_k - [\nabla^2 f(x_k)]^{-1} \nabla f(x_k) , k = 0, 1, \dots , x_0 - \text{dat}$$

# Metoda Newton - convergența

## Teorema 8

Fie  $f \in C^3(\mathbb{R}^n)$  o funcție care are un punct de minim local  $x^*$ , pentru care matricea Hessiană,  $\nabla^2 f(x^*)$ , este pozitiv definită. Dacă iterația inițială  $x_0$  este suficient de apropiată de soluția  $x^*$ ,  $\|x_0 - x^*\| \leq r$ , atunci șirul  $\{x_k\}$  construit cu metoda lui Newton converge la  $x^*$  și ordinul de convergență este cel puțin 2:

$$x_k \longrightarrow x^* \quad , \quad k \longrightarrow \infty \quad , \quad \|x_0 - x^*\| \leq r.$$

# Metode cvasi-Newton - BFGS

Se folosesc aproximări, calculate iterativ, ale matricei Hessiene sau ale inversei acestei matrice.

## Metoda Broyden-Fletcher-Goldfarb-Shanno

1.  $x_0$  - dat,  $H_0 = I_n$  sau  $H_0 = a I_n$ ,  $k = 0$ ;
2. Calculeaza direcția de căutare  $p_k = -H_k \nabla f(x_k)$ ;
3. Calculează  $\alpha_k > 0$  cu ajustarea inexactă a pasului Wolfe

4.  $x_{k+1} = x_k + \alpha_k p_k$

5.  $s_k = x_{k+1} - x_k$  ,  $y_k = \nabla f(x_{k+1}) - \nabla f(x_k)$  ,  $\rho_k = \frac{1}{y_k^T s_k}$

6. Se actualizează matricea  $H_{k+1}$

$$H_{k+1} = (I - \rho_k y_k s_k^T) H_k (I - \rho_k y_k s_k^T) + \rho_k s_k s_k^T$$

7.  $k = k + 1$

# Metode cvasi-Newton

Metoda **SR1** (symmetric-rank-1)

$$H_{k+1} = H_k + \frac{1}{(s_k - H_k y_k)^T y_k} [(s_k - H_k y_k)(s_k - H_k y_k)^T]$$

Metode **Broyden**

$$B_{k+1} = B_k + \frac{1}{u_k^T s_k} (y_k - B_k s_k) u_k^T$$

Alegerea vectorului  $u_k$  definește metoda de tip Broyden (este 'parametrul' metodei Broyden).

Cu  $H_k$  se notează aproximări ale inversei matricei Hessiene iar cu  $B_k$  aproximări ale matricei Hessiene.

# Metoda gradientelor conjugate (a direcțiilor conjugate)

Fie  $A \in \mathbb{R}^{n \times n}$ , o matrice simetrică,  $A = A^T$  și pozitiv definită și  $b \in \mathbb{R}^n$ .

Fie problema de minimizare a formei pătratice definite cu matricea  $A$  și vectorul  $b$ :

$$\min \{ f(x) = \frac{1}{2} x^T A x - x^T b; x \in \mathbb{R}^n \}.$$

## Definiție

Pentru o matrice  $A \in \mathbb{R}^{n \times n}$ , simetrică,  $A = A^T$ , doi vectori  $d_1, d_2 \in \mathbb{R}^n$  se numesc **A-ortogonali** sau **conjugate în raport cu A** dacă:

$$d_1^T A d_2 = (A d_2, d_1)_{\mathbb{R}^n} = (d_2, A d_1)_{\mathbb{R}^n} = (A d_1, d_2)_{\mathbb{R}^n} = 0.$$

# Metoda gradientelor conjugați

$A = 0_{n \times n} \Rightarrow \forall d_1, d_2$  sunt  $A$  ortogonali

$A = I_n \Rightarrow$  ortogonalitate clasică,  $(d_1, d_2)_{\mathbb{R}^n} = 0$ .

Vectorii  $\{d_0, d_1, \dots, d_k\}$  se numesc **A-ortogonali** sau **A-conjugați** dacă:

$$d_i^T A d_j = (A d_j, d_i)_{\mathbb{R}^n} = 0, \forall i \neq j, i, j = 0, 1, \dots, k.$$

## Propoziție

Fie  $A \in \mathbb{R}^{n \times n}$ , o matrice simetrică,  $A = A^T$  și pozitiv definită și  $\{d_0, d_1, \dots, d_k\}$  direcții  $A$ -conjugate,  $d_i \neq 0, \forall i = 0, \dots, k$ . Atunci vectorii  $\{d_0, d_1, \dots, d_k\}$  sunt liniar independenți.

# Metoda gradientilor conjugați

Dacă  $A \in \mathbb{R}^{n \times n}$ , este matrice simetrică,  $A = A^T$  și pozitiv definită, iar  $\{d_0, d_1, \dots, d_{n-1}\}$  sunt  $n$  direcții  $A$ -conjugate atunci  $\{d_0, d_1, \dots, d_{n-1}\}$  formează o bază în  $\mathbb{R}^n$ .

$$x^* = \arg \min \{f(x); x \in \mathbb{R}^n\} \Leftrightarrow x^* = A^{-1}b \quad (Ax^* = b)$$

Putem scrie soluția  $x^*$  în raport cu baza de  $n$  vectori  $A$ -conjugăți,  $\{d_0, d_1, \dots, d_{n-1}\}$ :

$$x^* = \alpha_0 d_0 + \alpha_1 d_1 + \dots + \alpha_{n-1} d_{n-1}$$

# Metoda gradientelor conjugați

Din relația:

$$(Ax^*, d_i)_{\mathbb{R}^n} = (b, d_i)_{\mathbb{R}^n} = d_i^T Ax^* = \alpha_i d_i^T Ad_i$$

rezultă că:

$$\alpha_i = \frac{d_i^T b}{d_i^T Ad_i} = \frac{(b, d_i)_{\mathbb{R}^n}}{(Ad_i, d_i)_{\mathbb{R}^n}}$$

Dacă știm  $n$  direcții  $A$ -conjugate, soluția sistemului  $Ax = b$  și a problemei de minimizare cu forme pătratice se poate scrie astfel:

$$x^* = \sum_{i=0}^{n-1} \frac{(b, d_i)_{\mathbb{R}^n}}{(Ad_i, d_i)_{\mathbb{R}^n}} d_i$$

# Metoda gradientilor conjugați

Procesul iterativ:

$$x_0 \in \mathbb{R}^n - \text{dat}$$

$$g_k = Ax_k - b \quad , \quad \alpha_k = -\frac{g_k^T d_k}{d_k^T A d_k}$$

$$x_{k+1} = x_k + \alpha_k d_k \quad , \quad k = 0, 1, 2, \dots, n-1$$

are proprietatea că  $x_n = x^*$ .

Considerăm următoarele relații:

$$x_k = x_0 + \alpha_0 d_0 + \alpha_1 d_1 + \dots + \alpha_{k-1} d_{k-1}$$

$$x^* = x_0 + \beta_0 d_0 + \beta_1 d_1 + \dots + \beta_{n-1} d_{n-1}$$

# Metoda gradientilor conjugați

Avem următoarele relații:

$$\alpha_i = \frac{d_i^T A(x_k - x_0)}{d_i^T A d_i} \quad , \quad \beta_i = \frac{d_i^T A(x^* - x_0)}{d_i^T A d_i}$$

$$d_k^T A(x_k - x_0) = 0.$$

$$x^* - x_k = (\beta_0 - \alpha_0) d_0 + \dots + (\beta_{k-1} - \alpha_{k-1}) d_{k-1} + \beta_k d_k + \dots + \beta_{n-1} d_{n-1}.$$

$$g_k^T d_i = 0 \quad \forall i < k.$$

# Algoritmul gradientilor conjugați

$$x_0 \in \mathbb{R}^n, g_0 = Ax_0 - b$$

$$d_0 = -g_0 = b - Ax_0$$

$$\alpha_k = -\frac{g_k^T d_k}{d_k^T A d_k}$$

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

$$g_{k+1} = Ax_{k+1} - b \text{ sau } g_{k+1} = g_k + \alpha_k A d_k$$

$$\beta_k = \frac{g_{k+1}^T A d_k}{d_k^T A d_k}$$

$$d_{k+1} = -g_{k+1} + \beta_k d_k$$

# Metoda gradientilor conjugați

Fie  $y_1, y_2, \dots, y_p \in \mathbb{R}^n$ . Facem următoarea notație:

$$\begin{aligned}\text{span}\{y_1, y_2, \dots, y_p\} &= \{y \in \mathbb{R}^n; y = a_1 y_1 + \dots + a_p y_p, a_i \in \mathbb{R}\} \\ &= \text{subspațiul generat de vectorii } y_1, y_2, \dots\end{aligned}$$

$$\mathcal{K}(g_0, k) = \text{span}\{g_0, Ag_0, \dots, A^k g_0\}$$

Acest subspațiu se numește **subspațiu Krylov de grad  $k$  pentru vectorul  $g_0$** .

# Metoda gradientilor conjugați

## Teorema 9

Presupunem că  $x_k \neq x^*$ . Avem relațiile:

$$(1) \quad g_k^T g_i = 0 \quad , \quad \forall i = 0, 1, \dots, k-1$$

$$(2) \quad \text{span}\{g_0, g_1, \dots, g_k\} = \text{span}\{g_0, Ag_0, \dots, A^k g_0\}$$

$$(3) \quad \text{span}\{d_0, d_1, \dots, d_k\} = \text{span}\{g_0, Ag_0, \dots, A^k g_0\}$$

$$(4) \quad d_k^T A d_i = 0 \quad , \quad \forall i = 0, 1, \dots, k-1$$

Șirul  $x_k$  converge la soluția  $x^*$  în cel mult  $n$  pași.

# Algoritmul gradientilor conjugați - forma practică

$$x_0 \in \mathbb{R}^n - \text{dat}, k = 0$$

$$g_0 = Ax_0 - b, d_0 = -g_0$$

**while** ( $g_k \neq 0$ )

$$\alpha_k = -\frac{g_k^T g_k}{d_k^T A d_k}$$

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

$$g_{k+1} = g_k + \alpha_k A d_k$$

$$\beta_k = \frac{g_{k+1}^T g_{k+1}}{g_k^T g_k}$$

$$d_{k+1} = -g_{k+1} + \beta_k d_k$$

$$k = k + 1$$

# Metoda gradientilor conjugați - convergența

Cu ajutorul unei matrice  $A$  în  $\mathbb{R}^{n \times n}$  simetrică și pozitiv definită, se definește următoarea normă matriceală:

$$\|x\|_A = \sqrt{(Ax, x)_{\mathbb{R}^n}}$$

## Teorema 10

Dacă matricea  $A$  are doar  $r$  valori proprii distincte, atunci algoritmul gradientilor conjugați calculează soluția  $x^*$  în cel mult  $r$  iterații

# Metoda gradientilor conjugați - convergența

## Teorema 11

Dacă  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$  sunt valorile proprii ale matricei  $A$  atunci:

$$\|x_{k+1} - x^*\|_A^2 \leq \left( \frac{\lambda_{n-k} - \lambda_1}{\lambda_{n-k} + \lambda_1} \right)^2 \|x_0 - x^*\|_A^2$$

$$\|x_{k+1} - x^*\|_A^2 = 2E(x_{k+1})$$

$$E(x_{k+1}) \leq \left( \frac{\lambda_{n-k} - \lambda_1}{\lambda_{n-k} + \lambda_1} \right)^2 E(x_0)$$

# Metodele gradientilor conjugați neliniare

$\min \{f(x); x \in \mathbb{R}^n\}$  ,  $f$  funcție oarecare, neliniară

Pentru a calcula elementul  $x_{k+1}$ , se folosește aproximarea pătritică a funcției  $f$  dată de dezvoltarea în serie Taylor în jurul punctului  $x_k$ :

$$f(x) \approx f(x_k) = f(x_k) + (x - x_k)^T \nabla f(x_k) + \frac{1}{2} (x - x_k)^T \nabla^2 f(x_k) (x - x_k)$$

În metoda gradientilor conjugați se fac următoarele înlocuiri:

$$\begin{aligned} g_k &\leftrightarrow \nabla f(x_k) \\ A &\leftrightarrow \nabla^2 f(x_k) \end{aligned}$$

# Algoritmul gradientilor conjugați - funcții oarecare

$$x_0 \in \mathbb{R}^n - \text{dat} , k = 0$$

$$g_0 = \nabla f(x_0); d_0 = -g_0$$

**while** ( $g_k \neq 0$ )

$$A = \nabla^2 f(x_k);$$

$$\alpha_k = -\frac{g_k^T d_k}{d_k^T A d_k}$$

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

$$g_{k+1} = \nabla f(x_{k+1})$$

$$\beta_k = \frac{g_{k+1}^T A d_k}{d_k^T A d_k}$$

$$d_{k+1} = -g_{k+1} + \beta_k d_k$$

$$k = k + 1$$

# Algoritmul gradientilor conjugați - metoda Fletcher-Reeves

$$x_0 \in \mathbb{R}^n - \text{dat} , k = 0$$

$$g_0 = \nabla f(x_0); d_0 = -g_0$$

**while** ( $g_k \neq 0$ )

$$\alpha_k = \min \{ f(x_k + \alpha d_k); \alpha \in [0, \bar{\alpha}) \}$$

(exact sau inexact cu testul Wolfe)

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

$$g_{k+1} = \nabla f(x_{k+1})$$

$$\beta_k^{\text{FR}} = \frac{g_{k+1}^T g_k}{g_k^T g_k}$$

$$d_{k+1} = -g_{k+1} + \beta_k^{\text{FR}} d_k$$

$$k = k + 1$$

# Metoda Fletcher-Reeves

Sunt vectorii  $d_k$  construiți cu metoda Fletcher-Reeves direcții de descreștere?

$$d_k = -g_k + \beta_{k-1}d_{k-1}$$

$$g_k^T d_k = -g_k^T g_k + \beta_{k-1} g_k^T d_{k-1}$$

Dacă se folosește ajustarea exactă a pasului:

$\alpha_{k-1}$  este punctul de minim local pentru funcția  $f$  pe direcția  $d_{k-1}$ , ceea ce implică faptul că:

$$\nabla f(x_k)^T d_{k-1} = g_k^T d_{k-1} = 0$$

Prin urmare:

$$g_k^T d_k = -g_k^T g_k = -\|g_k\|_2^2 < 0 \Rightarrow d_k \text{ direcție de descreștere.}$$

# Metoda Fletcher-Reeves

Dacă se folosește ajustarea inexactă a pasului am putea avea  $g_k^T d_k > 0$  ( $d_k$  direcție de creștere!!) dar dacă se folosește testului Wolfe avem:

$$f(x_k + \alpha_k d_k) \leq f(x_k) + \epsilon \alpha_k g_k^T d_k$$

$$|\nabla f(x_k + \alpha_k d_k)^T d_k| \leq (1 - \epsilon) |g_k^T d_k|$$

$$\epsilon \in \left(0, \frac{1}{2}\right) \Rightarrow g_k^T d_k < 0.$$

# Metoda Polak-Ribière

Este o variantă a metodei Fletcher-Reeves:

$$\beta_k^{\text{PR}} = \frac{g_{k+1}^T (g_{k+1} - g_k)}{g_k^T g_k}$$

Dacă se face ajustarea inexactă a pasului cu testul lui Wolfe, nu putem deduce că  $d_k$  sunt direcții de descreștere. Se folosește modificarea:

$$\beta_k^+ = \max \{ \beta_k^{\text{PR}}, 0 \}$$

și un test Wolfe adaptat pentru a face direcțiile  $d_k$ , direcții de descreștere.

# Varianta Hestenes-Stiefel

$$\beta_k^{\text{HS}} = \frac{g_{k+1}^T (g_{k+1} - g_k)}{(g_{k+1} - g_k)^T d_k}$$