

---

# Gradient, Minimum, Convexité et Optimisation

Loïc Neyrat, Yannis Formery

---

## Table des matières

1	Calcul de gradient	2
2	Condition d'optimalité à l'ordre 1	3
3	Analyse : matrice hessienne	4
4	Conditions d'optimalité à l'ordre 2	5
5	Existence du minimum	5
6	Unicité du minimum	5
7	Convexité	5
8	Application 1 : Méthode des moindres aux carrés	6
9	Matrice pseudo-inverse	7
10	Descente de gradient	8
11	Conditions nécessaires d'optimalité : intuition	9
12	Conditions d'optimalité nécessaires : Karush-Kuhn-Tucker	10

# 1 Calcul de gradient

**Rappel :** Le gradient est une application caractérisant la pente d'une fonction en chaque de son ensemble de définition.

**Exercice (calcul de gradients).** Soient  $x \in \mathbf{R}^n$  un vecteur de dimension  $n$  et  $A \in \mathcal{M}_n(\mathbf{R})$  une matrice réelle de taille  $n$  par  $n$ . Soient deux fonctions  $f$  et  $g$  définies par :

$$f : \begin{cases} \mathbf{R}^n & \rightarrow \mathbf{R} \\ x & \mapsto \|x\|_2 \end{cases}$$

$$g : \begin{cases} \mathbf{R}^n & \rightarrow \mathbf{R} \\ x & \mapsto x^T A x \end{cases}$$

Calculer les gradients  $\nabla f$  et  $\nabla g$ .

**Correction :**

— Nous pouvons réécrire la norme 2 de  $x$  de la manière suivante :

$$\|x\|_2 = \sqrt{x^T x}$$

Ainsi,  $f$  peut être vu comme la composition de deux fonctions  $f_1$  et  $f_2$  (i.e.  $f = f_1 \circ f_2$ ) telles que :

$$f_1 : \begin{cases} \mathbf{R}^+ & \rightarrow \mathbf{R} \\ x & \mapsto \sqrt{x} \end{cases}$$

$$f_2 : \begin{cases} \mathbf{R}^n & \rightarrow \mathbf{R} \\ x & \mapsto x^T x \end{cases}$$

Donc, par application de la Chain Rule, et sachant que  $f_1$  est dérivable sur  $\mathbf{R}^+$ , le gradient  $\nabla f$  de  $f$  est définie par :

$$\nabla f : \begin{cases} \mathbf{R}^n & \rightarrow \mathbf{R}^n \\ x & \mapsto \frac{\partial f_1}{\partial f_2} \nabla f_2 \end{cases}$$

Calculons la dérivée partielle de  $f_2$  par rapport à une composante  $x_k$  de  $x$  :

$$\begin{aligned} \frac{\partial}{\partial x_k} f_2 &= \frac{\partial}{\partial x_k} x^T x \\ &= \frac{\partial}{\partial x_k} \sum_{i=1}^n x_i^2 \\ &= \frac{\partial}{\partial x_k} x_k^2 \\ &= 2x_k \end{aligned}$$

Enfin, par définition du gradient, et en sachant que  $\frac{\partial f_1}{\partial x^T x} = \frac{\partial \sqrt{x^T x}}{\partial x^T x} = \frac{1}{2\sqrt{x^T x}}$ , on obtient :

$$\begin{aligned}\nabla f &= \left[ \frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right]^T \\ &= \left[ \frac{\partial f_1}{\partial f_2} \frac{\partial}{\partial x_1} f_2, \dots, \frac{\partial f_1}{\partial f_2} \frac{\partial}{\partial x_n} f_2 \right]^T \\ &= \frac{\partial f_1}{\partial f_2} \left[ \frac{\partial}{\partial x_1} f_2, \dots, \frac{\partial}{\partial x_n} f_2 \right]^T \\ &= \frac{\partial f_1}{\partial f_2} \left[ \frac{\partial}{\partial x_1} f_2, \dots, \frac{\partial}{\partial x_n} f_2 \right]^T \\ &= \frac{1}{2\sqrt{x^T x}} [2x_1, \dots, 2x_n]^T \\ &= \frac{x}{\|x\|}\end{aligned}$$

— Le gradient de  $g$  est définie comme suit :

$$\nabla g : \begin{cases} \mathbf{R}^n & \rightarrow \mathbf{R}^n \\ x & \mapsto \nabla x^T A x = \left[ \frac{\partial}{\partial x_1} x^T A x, \dots, \frac{\partial}{\partial x_n} x^T A x \right]^T \end{cases} \quad (1)$$

Développons la dérivée partielle de  $g$  par rapport à une composante  $x_k$  de  $x$  :

$$\begin{aligned}\frac{\partial}{\partial x_k} f_2 &= \frac{\partial}{\partial x_k} x^T A x \\ &= \frac{\partial}{\partial x_k} \sum_{i=1}^n \sum_{j=1}^n x_i a_{i,j} x_j \\ &= \frac{\partial}{\partial x_k} \sum_{i=1}^n x_i a_{i,k} x_k + x_k a_{k,i} x_i \\ &= \frac{\partial}{\partial x_k} \sum_{i=1}^n x_i a_{i,k} x_k + x_k a_{k,i} x_i \quad (\text{Si } A \text{ est symétrique, } a_{i,k} = a_{k,i}) \\ &= \sum_{i=1}^n a_{i,k} x_i + a_{k,i} x_i \\ &= (A^T x)_k + (Ax)_k \\ &= ((A^T + A)x)_k\end{aligned}$$

Donc par (1) :

$$\begin{aligned}\nabla g &= \left[ \frac{\partial}{\partial x_1} x^T A x, \dots, \frac{\partial}{\partial x_n} x^T A x \right]^T \\ &= [((A^T + A)x)_1, \dots, ((A^T + A)x)_n]^T \\ &= (A^T + A)x\end{aligned}$$

## 2 Condition d'optimalité à l'ordre 1

**Rappel sur les ouverts :** Soit  $U$  un ensemble de  $\mathbb{R}^n$ . On dit que  $U$  est un ouvert de  $\mathbb{R}^n$  si et seulement si  $\forall u \in U, \exists r > 0$  tel que  $\{x \in \mathbb{R}^n \mid \|x - u\|_2 < r\} \subset U$

**Théorème 1 (Conditions d'optimalité nécessaires à l'ordre 1)** Si  $x^*$  est un minimum local et  $f$  est de classe  $\mathcal{C}^1$  (dérivable une fois) sur un ouvert  $U \in \mathbb{R}^n$  contenant  $x^*$ , alors  $\nabla f(x^*) = 0$

Puisque tout maximum global est un maximum local, il est utile de noter que le théorème 1 peut s'appliquer dans le cas d'un maximum global. Attention cependant, car la réciproque n'est pas vraie : si  $\nabla f(x) = 0$  pour un  $x$ , selon ne veut pas forcément dire que  $f$  atteint un minimum local en  $x$ . En effet,  $x$  peut être un point selle ou plus généralement tout autre point où  $f$  admet une tangente constante.

**Exemple d'ensemble ouvert :**

Soit  $f$  une fonction définie par :

$$f : \begin{cases} [0; \pi] & \rightarrow \mathbf{R} \\ x & \mapsto \sin(x) \end{cases}$$

dont on suppose d'être de classe  $\mathcal{C}^1$  et d'admettre un minimum global sur  $[0; \pi]$ .

$f$  est définie sur l'ensemble fermé  $[0; \pi]$ . Restreignons  $f$  à l'ouvert  $]0; \pi[$  et notons  $f_{]0; \pi[}$  cette restriction. Par disjonction de cas :

1. Si  $x^*$  est un minimum global de  $f_{]0; \pi[}$ , alors  $x^*$  est un minimum local se  $f_{]0; \pi[}$  et  $\nabla f(x^*) = 0$ . Soit  $x \in ]0; \pi[$  tel que  $\nabla f(x) = \cos(x) = 0$ . Alors  $x = \frac{\pi}{2}$ . Donc  $x^* = \frac{\pi}{2}$  et  $\sin(x^*) = 1$ .
2. Si  $x^*$  est un minimum global de  $f_{]0; \pi[}$ , et  $x^* \notin ]0; \pi[$ , alors  $x^* = 0$  ou  $x^* = \pi$  donc  $f(x^*) = 0$ . Or  $\sin(\frac{\pi}{2}) = 1 > \sin(\pi) = \sin(0) = 0$  donc  $\{0, \pi\}$  sont des minimas globaux de  $f$ .

### 3 Analyse : matrice hessienne

Soit  $f$  une fonction numérique

$$f : U \subset \mathbf{R}^n \rightarrow \mathbf{R}$$

et

$$x = [x_1, \dots, x_n]^T \in \mathbf{R}^n$$

Si toutes les dérivées partielles seconde de  $f$  existent, la matrice hessienne de  $f$ , notée  $\nabla^2 f$  ou  $H(f)$ , est définie par :

$$\nabla^2 f = H(f) = \begin{bmatrix} \frac{\partial}{\partial^2 x_1} f & \frac{\partial}{\partial x_1 \partial x_2} f & \cdots & \frac{\partial}{\partial x_1 \partial x_n} f \\ \frac{\partial}{\partial^2 x_2} f & \frac{\partial}{\partial^2 x_2} f & \cdots & \frac{\partial}{\partial x_2 \partial x_n} f \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial}{\partial x_n \partial x_1} f & \frac{\partial}{\partial x_n \partial x_2} f & \cdots & \frac{\partial}{\partial^2 x_n} f \end{bmatrix}$$

De manière plus intuitive, la matrice hessienne est une application décrivant une forme quadratique en chaque point de l'ensemble de définition d'une fonction (par exemple, si c'est une parabole,...). **Un exemple :** Posons  $M \in \mathcal{M}_n(\mathbf{R})$  et

$$f : \begin{cases} \mathbf{R}^n & \rightarrow \mathbf{R} \\ x & \mapsto x^T M x \end{cases}$$

En nous servant des résultats obtenus lors de la résolution de l'exercice de calculs de gradients, on a :

$$\nabla f = (M^T + M)x$$

Alors,

$$\nabla^2 f = H(f) = \begin{bmatrix} \frac{\partial}{\partial^2 x_1} f & \frac{\partial}{\partial x_1 \partial x_2} f & \cdots & \frac{\partial}{\partial x_1 \partial x_n} f \\ \frac{\partial}{\partial^2 x_2} f & \frac{\partial}{\partial^2 x_2} f & \cdots & \frac{\partial}{\partial x_2 \partial x_n} f \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial}{\partial x_n \partial x_1} f & \frac{\partial}{\partial x_n \partial x_2} f & \cdots & \frac{\partial}{\partial^2 x_n} f \end{bmatrix} = \begin{bmatrix} \frac{\partial}{\partial x_1} (M^T + M)x \\ \frac{\partial}{\partial x_2} (M^T + M)x \\ \vdots \\ \frac{\partial}{\partial x_n} (M^T + M)x \end{bmatrix} = M^T + M$$

## 4 Conditions d'optimalité à l'ordre 2

Les deux théorèmes suivants explicitent les conditions nécessaires suffisantes d'optimalité à l'ordre 2.

**Théorème 2 (Conditions nécessaires d'optimalité à l'ordre 2)** *Si  $x^*$  est un minimum local et  $f$  est de classe  $C^2$  sur un ouvert  $U \subset \mathbf{R}^n$  contenant  $x$ , alors  $\nabla f(x^*) = 0$  et  $\nabla^2 f(x^*)$  est semi-définie positive.*

**Théorème 3 (Conditions suffisantes d'optimalité à l'ordre 2)** *Si  $f$  est de classe  $C^2$  sur un ouvert  $U \subset \mathbf{R}^n$  contenant  $x$ , si  $\nabla f(x^*) = 0$  et  $\nabla^2 f(x^*)$  est définie positive, alors  $x^*$  est un minimum local.*

**Attention :** contrairement à l'ordre 1, les théorèmes précédents ne s'appliquent qu'aux minimas locaux. De plus, pour qualifier un maximum local, il est nécessaire que  $-H$  soit semi-définie positive.

## 5 Existence du minimum

Voici deux théorèmes importants permettant de montrer l'existence d'un ou de plusieurs minimas globaux d'une fonction sous certaines conditions.

**Théorème 4 (Théorème de Weierstrass)** *Si  $f$  est définie et continue sur un sous-ensemble fermé et borné de  $\mathbf{R}^n$ , alors  $f$  admet un minimum global.*

**Théorème 5** *Si  $f$  est définie et continue sur  $\mathbf{R}^n$  et coercive (i.e.  $f(x) \rightarrow +\infty$  quand  $\|x\| \rightarrow +\infty$ ), alors  $f$  admet un minimum global sur tout sous-ensemble fermé de  $\mathbf{R}^n$ .*

**Note :** une fonction est dite *coercive* si elle tend vers  $+\infty$  lorsque  $x$  s'éloigne en norme de l'origine. De façon plus formelle,  $f$  est coercive si  $\|x\| \rightarrow +\infty \Rightarrow f(x) \rightarrow +\infty$

## 6 Unicité du minimum

**Théorème 6 (Unicité du minimum)** *Si  $f$  est une fonction strictement convexe définie sur un ensemble convexe  $X \subset \mathbf{R}^n$ , alors  $f$  admet au plus un minimum global.*

## 7 Convexité

**Théorème 7 (Convexité d'un ensemble)** *L'ensemble  $X$  est convexe si et seulement si  $\forall x, y \in X$ , le segment  $[x, y] = \{tx + (1-t)y \mid t \in [0, 1]\}$  est inclus dans  $X$ .*

**Théorème 8 (Convexité d'une fonction à valeurs réelles)** *Une fonction  $f : X \subset \mathbf{R}^n \rightarrow \mathbf{R}$  est convexe si et seulement si  $X$  est convexe et  $\forall x, y \in X$  et  $\forall t \in [0, 1]$ ,*

$$f(tx + (1-t)y) \leq tf(x) + (1-t)f(y)$$

*Si l'inégalité est stricte pour  $t \in ]0, 1[$ , la fonction est dite strictement convexe.*

Ces deux théorèmes, associés au théorème de l'unicité du minimum, permettent notamment de prouver que si une fonction  $f$  définie sur un ensemble convexe  $X \subset \mathbf{R}^n$  est strictement convexe, alors  $f$  admet au plus un minimum global.

Un autre théorème utile est le suivant :

**Théorème 9** *Si  $f$  est une fonction convexe définie sur un ensemble convexe  $X \subset \mathbf{R}^n$ , alors tout minimum local de  $f$  est aussi un minimum global de  $f$ . Si  $X$  est ouvert, alors  $\nabla f(x^*) = 0$  et  $x^*$  est un minimum global de  $f$ .*

Voici une liste de quelques familles de fonctions convexes à savoir reconnaître. **Astuces pour reconnaître qu'une fonction est convexe :**

- les fonctions linéaires sont convexes.
- les combinaisons linéaires positives (à poids positifs) de fonctions convexes sont convexes.
- le maximum (point par point) d'un ensemble de fonctions convexes est convexe.

Enfin, pour reconnaître une fonction convexe, on peut utiliser le théorème suivant :

**Théorème 10** *Si  $f$  est de classe  $\mathcal{C}^2$ , alors  $f$  est convexe si et seulement si  $\nabla^2(f)$  est semi-définie positive sur l'intérieur de  $X$ . Si  $\nabla^2(f)$  est définie positive sur l'intérieur de  $X$ ,  $f$  est strictement convexe.*

**Exercice d'application :**

Déterminons la convexité ou non-convexité de la fonction  $f$  définie par :

$$f : \begin{cases} \mathbf{R}^2 & \rightarrow \mathbf{R} \\ x, y & \mapsto xy + x^2 + 2y + 1 \end{cases}$$

Calculons son gradient et sa matrice hessienne :

$$\begin{aligned} \nabla f(x, y) &= \begin{bmatrix} \frac{\partial}{\partial x} f(x, y) \\ \frac{\partial}{\partial y} f(x, y) \end{bmatrix} = \begin{bmatrix} y + 2x \\ x + 2 \end{bmatrix} \\ \nabla^2 f = H(f) &= \begin{bmatrix} \frac{\partial^2}{\partial x^2} f & \frac{\partial^2}{\partial x \partial y} f \\ \frac{\partial^2}{\partial y \partial x} f & \frac{\partial^2}{\partial y^2} f \end{bmatrix} = \begin{bmatrix} 2 & 1 \\ 1 & 0 \end{bmatrix} \end{aligned}$$

Son polynôme caractéristique est donné par :

$$\chi = \det(\nabla^2 f) = |\nabla^2 f - XI| = (X - 1 - \sqrt{2})(X - 1 + \sqrt{2})$$

Par conséquent, toutes les valeurs propres de la matrice hessienne ne sont pas toutes positives (par exemple,  $1 - \sqrt{2} < 0$  est une racine de  $\chi$ ). Donc  $f$  n'est pas convexe.

De façon générale, pour montrer qu'une n'est pas convexe dans les conditions de l'exercice précédent, il faut soit montrer que la matrice hessienne est (semi)-définie positive, ou alors montrer qu'il existe  $(u, v) \in \mathbf{R}^2$  tels que :

$$\begin{bmatrix} u & v \end{bmatrix} \nabla^2 f(x, y) \begin{bmatrix} u \\ v \end{bmatrix} < 0$$

Une dernière approche se base sur la formule définissant le déterminant d'une matrice  $A$  comme  $\det(A) = \prod_i \lambda_i$ ,  $\lambda_i \in sp(A)$  avec  $sp(A)$  le spectre de  $A$ . Elle consiste à montrer que  $\det(\nabla^2 f(x, y)) < 0$ , c'est-à-dire qu'il existe une valeur propre  $\lambda$  de  $\nabla^2 f(x, y)$  strictement négative, et donc que  $\nabla^2 f(x, y)$  n'est pas semi-définie positive.

## 8 Application 1 : Méthode des moindres aux carrés

Soit

$$C = \|Ax - y\|_2$$

avec  $A \in \mathcal{M}_{m,n}(\mathbf{R})$ ,  $x \in \mathbf{R}^n$  et  $y \in \mathbf{R}^m$ . Montrer que  $C$  admet un minimum global  $x^*$  et donner une expression de ce minimum.

Le problème posé revient à résoudre le problème d'optimisation :

$$x^* = \min_{x \in \mathbf{R}^n} C$$

L'application d'une fonction croissante ne change pas l'antécédent du minimum par  $C$ . Or la fonction carrée est croissante sur  $\mathbf{R}^+$ . Donc minimiser  $C$  revient à minimiser  $C^2$ .

On pose

$$C^2 : \min_{x \in \mathbf{R}^n} \|Ax - y\|_2^2$$

Calculons le gradient  $C^2$ .

$$\begin{aligned} \nabla C^2 &= \nabla \|Ax - y\|_2^2 \\ &= \nabla (Ax - y)^T (Ax - y) \\ &= \nabla (x^T A^T Ax - x^T A^T y - y^T Ax + y^T y) \\ &= \nabla (x^T A^T Ax) - \nabla (x^T A^T y) - \nabla (y^T Ax) + \nabla (y^T y) \\ &= \nabla (x^T A^T Ax) - \nabla (x^T A^T y) - \nabla (y^T Ax) && \text{Car } \nabla y^T y = 0, \text{ puisque ce terme ne dépend pas de } x \\ &= [A^T A + (A^T A)^T] x - 2A^T y && \text{Car } \nabla y^T Ax \in \mathbf{R} \text{ et } (y^T Ax = x^T A^T y)^T, \text{ donc } y^T Ax = x^T A^T y \\ &= 2A^T Ax - 2A^T y \\ &= 2A^T (Ax - y) \end{aligned}$$

De même, on peut calculer la hessienne de  $C^2$  :

$$\begin{aligned} \nabla^2 C^2 &= \nabla \nabla C^2 \\ &= \nabla 2A^T (Ax - y) \\ &= \nabla 2A^T Ax - 2A^T y \\ &= 2A^T A \end{aligned}$$

Or on sait que les valeurs propres de  $A^T A$  sont les carrés des valeurs singulières de  $A$ . Donc  $\nabla^2 C^2$  est semi-définie positive, nous permettant de conclure que  $C^2$  est convexe. Il restera alors à montrer que  $C^2$  admet un minimum global. Une fois l'existence d'un tel minimum démontrée, on a, si  $A^T A$  est inversible :

$$\begin{aligned} \nabla C^2 &= 0 \\ \Leftrightarrow 2A^T (Ax^* - y) &= 0 \\ \Leftrightarrow A^T (Ax^* - y) &= 0 \\ \Leftrightarrow A^T Ax^* - A^T y &= 0 \\ \Leftrightarrow A^T Ax^* &= A^T y \\ \Leftrightarrow x^* &= (A^T A)^{-1} A^T y \end{aligned}$$

## 9 Matrice pseudo-inverse

Une vision non-formelle et imparfaite d'une matrice pseudo-inverse est la généralisation de la notion de matrice inverse aux matrices rectangulaires.

Soit  $A$  une matrice réelle de taille  $m$  par  $n$  et de rang  $r$ . Soit  $A = U\Sigma V^T$  sa décomposition en valeurs singulières

avec, en notant  $\sigma_i$  la  $i^e$  valeur propre de  $A$  :

$$\Sigma = \begin{bmatrix} \sigma_1 & 0 & \dots & 0 & \dots & \dots & 0 \\ 0 & \sigma_2 & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & \sigma_r & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & 0 & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & 0 & 0 & \dots & 0 & 0 \end{bmatrix}$$

Alors on définit le conjugué de  $\Sigma$  comme :

$$\Sigma^\dagger = \begin{bmatrix} 1/\sigma_1 & 0 & \dots & 0 & \dots & \dots & 0 \\ 0 & 1/\sigma_2 & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & 1/\sigma_r & \ddots & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & 0 & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \ddots & 0 & 0 & \dots & 0 & 0 \end{bmatrix}$$

et la pseudo-inverse de  $A$  comme :

$$A^\dagger = V\Sigma^\dagger$$

Ainsi, on a que  $AA^\dagger = U\Sigma\Sigma^\dagger U^T = \Sigma\Sigma^\dagger$

$$AA^\dagger = U\Sigma\Sigma^\dagger U^T = \Sigma\Sigma^\dagger = \begin{bmatrix} I_r & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$$

Avec  $I_r$  la matrice identité de taille  $r$ .

Pour plus de détails, voir Moore-Penrose Pseudo-inverse

## 10 Descente de gradient

### 'Backtracking' avec la règle d'Armijo

Input:  $x_0 \in \mathbf{R}^n, f : \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1$ .

$$\text{Iteration : } x_{k+1} = x_k - \alpha_k \nabla f(x_k)$$

$$\alpha_k = \beta^{m_k} s$$

$m_k$  plus petit entier positif tel que

$$f(x_k) - f(x_{k+1}) \geq \sigma \beta^{m_k} s \nabla f(x_k)^T \nabla f(x_k)$$



### 'Backtracking' avec la règle d'Armijo

Input:  $x_0 \in \mathbf{R}^n, f : \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1$ .

$$\text{Iteration : } x_{k+1} = x_k - \alpha_k \nabla f(x_k)$$

$$\alpha_k = \beta^{m_k} s$$

$m_k$  plus petit entier positif tel que


$$f(x_k) - f(x_{k+1}) \geq \sigma \beta^{m_k} s \nabla f(x_k)^T \nabla f(x_k)$$

### Convergence

Soit  $(x_k)$  la suite des points générés par l'algorithme de descente de gradient avec pas choisi par la règle d'Armijo. Alors, tout point limite (i.e. valeur d'adhérence) de  $(x_k)$  est un point stationnaire.

De plus, si  $x^*$  est le seul point stationnaire de  $f$  dans un ensemble ouvert, il existe un ensemble ouvert  $S$  contenant  $x^*$  tel que si il existe  $k_0$  tel que  $x_{k_0} \in S$ , alors  $x_k \in S$  pour tout  $k \geq k_0$  et  $x_k \rightarrow x^*$ .

### Vitesse de convergence ?



## 11 Conditions nécessaires d'optimalité : intuition

Soit  $f$  définie sur  $\mathbf{R}^n$  une fonction à minimiser sous les contraintes  $c_i$ . Le problème d'optimisation sous contraintes s'exprime de la manière suivante :

$$\min_{x \in \mathbf{R}^n} f(x) \text{ subject to } \begin{cases} c_i(x) = 0, & i \in \mathcal{E} \\ c_i(x) \geq 0, & i \in \mathcal{I} \end{cases}$$


**Théorème 11**  $x^*$  est une solution locale du problème si et seulement si  $x^* \in \Omega$  et il existe un ensemble ouvert  $U \subset \mathbf{R}^n$  contenant  $x^*$  tel que pour tout  $x \in U \cap \Omega, f(x^*) \leq f(x)$

**Exemple :** Soit

$$f : \begin{cases} \mathbf{R}^2 & \rightarrow \mathbf{R} \\ x_1, x_2 & \mapsto x_1^2 + x_2^2 - 2 \end{cases} \quad (2)$$

Définissons la contrainte  $c_1 : x \mapsto x_1^2 + x_2^2 - 2$

Soit  $A(x)$  l'active set, c'est-à-dire l'ensemble des indices des contraintes d'égalité et d'inégalité tels que  $c_i(x) = 0$  pour un point  $x$  donné.



La solution se trouve au point où la tangente de  $f$  est orthogonale au gradient. Aussi, la normale à l'espace de contraintes est l'opposé du gradient.

## 12 Conditions d'optimalité nécessaires : Karush-Kuhn-Tucker

Les conditions de Karush-Kuhn-Tucker constituent une méthode de résolution de problèmes d'optimisation à contraintes d'inégalités, généralisant la méthode des multiplicateurs de Lagrange.

Considérons par exemple le problème suivant :

$$\mathcal{L}(x, \lambda) = f(x) - \sum_{i \in \mathcal{E} \cup \mathcal{I}} \lambda_i c_i(x)$$

sous contraintes

$$\begin{aligned} \nabla_x \mathcal{L}(x^*, \lambda^*) &= 0, \\ c_i(x^*) &= 0, \quad \text{for all } i \in \mathcal{E} \\ c_i(x^*) &\geq 0, \quad \text{for all } i \in \mathcal{I} \\ \lambda_i^* &\geq 0, \quad \text{for all } i \in \mathcal{I} \\ \lambda_i^* c_i(x^*) &= 0, \quad \text{for all } i \in \mathcal{E} \cup \mathcal{I} \end{aligned}$$

Comme on sait que  $x^*$  est la valeur de  $x$  en laquelle  $f$  atteint son minimum, on cherche à annuler les contraintes indiquées ci-dessus pour ce  $x^*$  fixé en trouvant les  $\lambda_i^*$  adéquats. D'où les  $\lambda_i^* c_i(x^*) = 0$ , for all  $i \in \mathcal{E} \cup \mathcal{I}$ . Les coefficients de Lagrange  $\lambda_i^*$  sont toujours positifs et on retrouve les contraintes sur les  $c_i(x^*)$  imposées dans le problème d'optimisation défini ci-dessus.