

UE Optimisation:

Introduction à l'optimisation

“La nature agit toujours par les voies les plus courtes et les plus simples”

Pierre de Fermat, 1657

Plan

- 1. Introduction


Introduction

■ Principe de moindre action

- En physique, le comportement observé d'un système correspond à la **minimisation** (ou à **la maximisation**) d'une certaine grandeur relative à ce phénomène.
- Principe d'abord phénoménologique mis en évidence au 17^e siècle en optique (Fermat).

Introduction

■ Principe de moindre action



Introduction

■ Principe de moindre action

- La lumière se propage d'un point à un autre sur des trajectoires telles que la durée du parcours est stationnaire.

- **Il s'agit d'un problème d'optimisation** : la durée du parcours doit être extrémale, en générale minimale, par rapport à une petite variation du trajet.

Introduction

■ Principe de moindre action

- A l'aide de ce principe, on démontre immédiatement la loi de propagation rectiligne de la lumière dans un milieu homogène...
- Et les lois de Snell-Descartes (réfraction, réflexion) qui en découlent.

Introduction



■ Le problème de la Reine Didon : l'isopérimétrie

- L'isopérimétrie a débuté avec le problème auquel a été confrontée la Reine Didon, qui a du trouver la forme de la frontière à poser au sol (en utilisant des bandes de peau de boeuf) **pour encercler une surface d'aire maximale.**
- Si l'on suppose la côte droite, alors la réponse, qui a manifestement été trouvée par la Reine Didon, est de poser ces bandes en forme de demi-cercle.
- C'est ainsi que Carthage serait né 😊


Introduction

■ Optimisation : une définition


- En mathématique, un problème d'optimisation consiste à trouver, parmi un ensemble donné, un élément* **minimisant ou maximisant une fonction donnée de cet ensemble sur \mathbb{R} .**

**dans le cadre de ce cours, il s'agira souvent d'un vecteur de \mathbb{R}^n mais ce peut être aussi un vecteur d'entiers, une fonction...*

Introduction




Chaîne logistique




Equilibrage de charge sur un réseau (*électrique, telecom*)

Traitement du signal, de l'image (*recalage*)



Planification (*Scheduling*)



Apprentissage statistique (*SVM*)

Introduction

- **Optimisation : en résumé**
 - L'art de formuler les problèmes (*de décision*)
 - Une théorie mathématique (*un mal nécessaire* 😊)
 - Des techniques algorithmiques

Entrons dans le vif du sujet

Plan

- 1. Introduction
- 2. **Formalisation**

Formalisation

- En écriture mathématique, optimiser c'est :

$$J(x^*) = \min_{x \in C} J(x) \quad \leftarrow x = (x_1, x_2, \dots, x_n)^T \in \mathfrak{R}^n$$

Fonction de coût
 $J : \mathfrak{R}^n \mapsto \mathfrak{R}$

Ensemble des contraintes
 $C \subset \mathfrak{R}^n$

Variables recherchées
 $x^* \in C$

Formalisation

- **Exemple : Le portefeuille de Markovitz**
 - *En français* : l'objectif est d'optimiser les sommes d'argent dédiées à divers placement bancaires (caractérisés par un rendement)
 - En minimisant les risques de perte...
 - Et en ne plaçant pas plus que ce qu'il y a sur notre compte en banque
 - *How to become rich?*

Formalisation

■ Exemple : Le portefeuille de Markovitz

□ *En langage « optimisation » :*

$$\min_{x \in \mathfrak{R}^n} \left(-\sum_1^n r_i x_i + \frac{1}{2} \alpha x^T \Sigma x \right); \quad x \geq 0, \quad \sum_1^n x_i = 1$$

- $r = (r_1, r_2, \dots, r_n)$ sont les rendements des parts investies
- α est un coefficient d'aversion au risque
- Σ la matrice de variance/covariance des montants placés

Formalisation

$$\min_{x \in \mathcal{R}^n} \left(- \sum_1^n r_i x_i + \frac{1}{2} \alpha x^T \Sigma x \right); \quad x \geq 0, \quad \sum_1^n x_i = 1$$

On maximise
l'objectif de
rendement

On minimise les
risques de placement
au regard d'un critère
donné

On ne place pas de
l'argent qu'on a pas !

**Les contraintes
définissent un
domaine de faisabilité**

Formalisation

- **Cas d'une fonction à une seule variable**

- *Minimisation*

$$J(x^*) = \min_{x \in C} J(x)$$

- *Illustration : Le problème du maître nageur*

Formalisation



■ Le problème du maître nageur

- Telle la lumière qui se propage moins vite dans l'eau que dans l'air, un(e) maître nageur(se) court plus vite qu'il (elle) ne nage.
- Il (elle) se trouve au point **A** (plage) lorsqu'il aperçoit un(e) jolie fille (garçon) qui se noie en **B** (océan).
- **Question** : Comment arriver en **B** le plus vite possible ?

Formalisation




■ Le problème du maître nageur

□ Réponse :

- Il faut trouver un compromis entre la ligne droite et le « chemin » qui **rend minimal le temps de parcours.**
- La réponse mathématique a été donnée par Maupertuis (bien avant David Hasselhoff !) en 1744.

Formalisation

■ Illustration :




La trajectoire du maître nageur est constituée de deux droites **AI** et **IB**, où $I(x, 0)$ est le point où le maître nageur plonge.

A priori la distance **AI** sera plus grande que la distance **IB** car il court plus vite qu'il ne nage.

Formalisation

■ Illustration :




La fonction temporelle t mis par le maître nageur pour aller de A en B est :

$$t(x) = \frac{AI}{v_1} + \frac{IB}{v_2}$$

Formalisation

■ Illustration :



$$t(x) = \frac{AI}{v_1} + \frac{IB}{v_2}$$

Problème de minimisation :

$$x^* = \arg \min_{x \in \mathfrak{R}^+} t(x)$$

Formalisation



- **Solution (à défaut d'avoir un hors-bord) :**
 - La fonction t est minimale quand sa dérivée première est nulle

$$\frac{dt(x)}{dx} = 0 = \frac{1}{v_1} \frac{x}{\sqrt{x^2 + a^2}} - \frac{1}{v_2} \frac{d-x}{\sqrt{(d-x)^2 + b^2}}$$

- **NB** Ou encore : $\frac{1}{v_1} \sin i_1 = \frac{1}{v_2} \sin i_2$


Formalisation

■ Quelques remarques

- Dans cet exemple, nous avons fait les hypothèses implicites suivantes :
 - Le minimum de la fonction t existe
 - La fonction t est dérivable (et même C^1)

□ Autres questions possibles

- Le minimum est-il unique ?
- Et si non, le minimum est-il
 - global ?
 - local ?



Formalisation

- **Quelques remarques**

- **Sur la solution**

- Dans ce cas simple, on peut la déterminer analytiquement en résolvant $t'(x)=0$,

Il s'agit alors d'une solution exacte


- Quand on ne peut résoudre analytiquement le problème, on cherche une solution approchée

On construit alors une suite x^k convergente (descente de gradient par exemple)


Formalisation

■ Problème multidimensionnel

- Même questionnement qu'à une variable mais en « un peu plus » compliqué
- *Exemple* : Algorithme des moindres carrés



On cherche à minimiser la somme des carrés des écarts des valeurs observées à la fonction « référence » utilisée pour la régression



Formalisation

■ Problème multidimensionnel

- **Même questionnement qu'à une variable mais en « un peu plus » compliqué**
- *Exemple* : Algorithme des moindres carrés


$$f(\theta^*) = \min_{\theta \in \mathcal{R}^n} \sum_1^P (y_i - g(x_i : \theta))^2$$

Résolution : $\nabla_{\theta} f(\theta^*) = 0$

← Résidu de l'erreur de distance de la fonction de paramètres aux données d'observations (x_i, y_i)

Formalisation


- **Problème multidimensionnel**
 - **Minimum global ou local**



$$x^* = \arg \min_{x \in \mathbb{R}^2} J(x)$$

$$x^l = \arg \min_{x \in V_\varepsilon(x^l)} J(x)$$

$V_\varepsilon(x)$ Un voisinage de x



Formalisation

■ Synthèse

- *Un problème d'optimisation c'est :*
 - *Une fonction de coût à minimiser*
 - *Très souvent des contraintes à respecter*

- *Les questions associées*
 - *Dimensionnalité de la variable ?*
 - *Propriété de la fonction de coût ? (continuité, dérivabilité, topologie, linéarité)*
 - *Unicité de la solution ?*
 - *Méthodes de résolution correspondantes ?*

Plan

- 1. Introduction
- 2. Formalisation
- 3. Rappels de mathématiques

“Rappels” de mathématiques

■ Quelques définitions fondamentales

□ *Définition 1 : produit scalaire*

Pour tout $x, y \in \mathfrak{R}^n$, on note $\langle x, y \rangle$ le produit scalaire de x et y
qui est donné par

$$\langle x, y \rangle = \sum_{i=1}^n x_i y_i = x^T y$$

“Rappels” de mathématiques

■ Quelques définitions fondamentales

□ *Définition 2 : norme euclidienne*

Pour tout $x \in \mathfrak{R}^n$, on note $\|x\| \geq 0$ la norme euclidienne de x
qui est donnée par

$$\|x\| = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{\langle x, x \rangle}$$

“Rappels” de mathématiques

■ Proposition 1

□ *Inégalité de Cauchy-Schwarz*

Pour tout $x, y \in \mathfrak{R}^n$

$$|\langle x, y \rangle| \leq \|x\| \cdot \|y\|$$

“Rappels” de mathématiques

■ Aparte sur la notion de norme

- *Soit E un espace vectoriel sur R .*
- *Une norme N est une application de E dans R telle que :*

$$\begin{aligned} 1. & \forall x \in E, \quad N(x) = 0 \Leftrightarrow x = 0 \\ 2. & \forall x \in E, \quad N(x) \geq 0 \\ 3. & \forall x, y \in E, \quad N(x + y) \leq N(x) + N(y) \\ 4. & \forall x \in E, \forall \lambda \in \mathfrak{R}, \quad N(\lambda x) = |\lambda|N(x) \end{aligned}$$

Rq: Un espace vectoriel muni d'une norme est appelé espace vectoriel normé (EVN)

“Rappels” de mathématiques

■ Aparte sur la notion de norme

□ Quelques exemples classiques sur \mathbb{R}^n

- La classique norme L^2 donc ou distance euclidienne

$$\forall x \in \mathbb{R}^n, \quad \|x\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$$

- La norme L^1

$$\forall x \in \mathbb{R}^n, \quad \|x\|_1 = |x_1| + |x_2| + \dots + |x_n|$$

“Rappels” de mathématiques

- **Aparte sur la notion de norme**

- *Quelques exemples classiques sur \mathbb{R}^n*

- *Et la norme L^∞*

$$\forall x \in \mathbb{R}^n, \quad \|x\|_\infty = \max(x_1, x_2, \dots, x_n)$$

“Rappels” de mathématiques

■ Quelques définitions fondamentales

- *Définition 3 : fonction de classe C^m*

Soit $\Omega \subset \mathbb{R}^n$, f est de classe C^m sur Ω
si toutes les dérivées partielles jusqu'à
l'ordre m de f existent et sont continues

“Rappels” de mathématiques

■ Quelques définitions fondamentales

□ *Définition 4 : Dérivées partielles*

Quand elle existe, on définit la dérivée partielle de la fonction f dans la direction x_i

de la manière suivante :

$$\frac{\partial f(x)}{\partial x_i} = \lim_{h \rightarrow 0} \frac{f(x + he_i) - f(x)}{h}$$

avec e_i le symbole de Kronecker

$$(e_i)_j = 1 \text{ si } i = j$$

0 sinon

“Rappels” de mathématiques

■ Quelques définitions fondamentales

□ *Définition 5 : Gradient*

Quand il existe, on note

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

le gradient de la fonction f

“Rappels” de mathématiques

■ Quelques définitions fondamentales

- *Définition 6 : Dérivée de f dans la direction h*

D'une manière générale, la dérivée de
de f dans la direction $d \in \mathfrak{R}^n$ est donnée par

$$\frac{\partial f(x)}{\partial d} = \langle \nabla f(x), d \rangle = \nabla f(x)^T d$$

“Rappels” de mathématiques

■ Quelques définitions fondamentales

□ *Définition 7 : Matrice hessienne de f*

Le Hessien de la fonction f quand il existe est la matrice telle que :

$$\left(\nabla^2 f(x)\right)_{ij} = \frac{\partial^2 f(x)}{\partial x_i \partial x_j}$$

Rq : Si la fonction f est C^2 le hessien est une matrice symétrique (Théorème de Schwarz)

“Rappels” de mathématiques

■ Proposition 2

□ *Formules de Taylor-Young*

Soit $a \in \Omega$ ($\subset \mathbb{R}^n$) et $h \in \mathbb{R}^n$

Si f est C^1 sur Ω

$$f(a+h) = f(a) + \langle \nabla f(a), h \rangle + o(\|h\|)$$

Si f est C^2 sur Ω

$$f(a+h) = f(a) + \langle \nabla f(a), h \rangle + \frac{1}{2} \langle \nabla^2 f(a) h, h \rangle + o(\|h\|^2)$$

“Rappels” de mathématiques

■ Définition 8

□ *Minimum absolu*

Soit $U \subset \mathfrak{R}^n$, $u^* \in U$ et $f : U \mapsto \mathfrak{R}$

On dit que u^* est un point de minimum **absolu** (ou global)
de f sur U si

$$f(u) \geq f(u^*), \forall u \in U$$

“Rappels” de mathématiques

■ Définition 9

□ *Minimum relatif*

Soit $U \subset \mathfrak{R}^n$, $u^* \in U$ et $f : U \mapsto \mathfrak{R}$

On dit que u^* est un point de minimum **relatif** (ou local) de f sur U si $\exists V$ un voisinage de u^* dans \mathfrak{R}^n tel que

$$f(u) \geq f(u^*), \quad \forall u \in U \cap V$$

“Rappels” de mathématiques

■ Théorème 1

□ *Condition nécessaire d’optimalité*

Soit $U \subset \mathbb{R}^n$, $u^* \in U$ et $f : U \mapsto \mathbb{R}$ de classe C^2

Si u^* est un minimum local de f sur U) alors

1. $\nabla f(u^*) = 0$
2. $\nabla^2 f(u^*)$ est une matrice définie positive

“Rappels” de mathématiques

■ Théorème 2

□ Condition suffisante d'optimalité

Soit $U \subset \mathfrak{R}^n$, $u^* \in U$ et $f : U \mapsto \mathfrak{R}$ de classe C^2

Si f vérifie en x^*

1. $\nabla f(u^*) = 0$

2. $\nabla^2 f(u^*)$ est une matrice définie positive

alors f admet un minimum local en u^*

Plan


- 1. Introduction
- 2. Formalisation
- 3. Rappels de mathématiques
- 4. Optimisation et convexité
- 5. Classification

Optimisation et convexité


■ Convexité

□ Ensemble convexe

Soit $U \subset \mathbb{R}^n$, U est convexe si
 $\forall x, y \in \mathbb{R}^n, [x, y] \subset U$



Convexe



Non-Convexe


Optimisation et convexité

■ Convexité


- *Ensemble convexe: notation équivalente*

Soit $U \subset \mathfrak{R}^n$, et $t \in [0,1]$, U est convexe si

$$\forall x, y \in R^n, \quad tx + (1-t)y \subset U$$



Convexe



Non-Convexe

Optimisation et convexité

■ Convexité

□ *Fonction convexe*

Soit $U \subset \mathfrak{R}^n$, $t \in [0,1]$, et $f : U \rightarrow \mathfrak{R}$,

f est convexe sur U ssi


$$\forall x, y \in R^n, \quad f(tx + (1-t)y) \leq t.f(x) + (1-t).f(y)$$

Rq : On parle de stricte convexité si l'inégalité ci-dessus est stricte

Optimisation et convexité

■ Convexité

□ *Fonction convexe : illustration*



Optimisation et convexité

■ Convexité

□ *Fonction convexe : en pratique*

- La condition précédente n'est en pratique pas simple à vérifier
- En pratique donc, on préfère utiliser des conditions sur le gradient ou le hessien.

Optimisation et convexité

■ Convexité

□ *Fonction convexe : en pratique*

- La condition précédente n'est en pratique pas simple à vérifier
- En pratique donc, on préfère utiliser des conditions sur le **gradient (si f est de classe C^1)** ou le hessien:

$$\begin{aligned} &\text{Soit } U \subset \mathbb{R}^n, \quad f : U \rightarrow \mathbb{R}, \\ &f \text{ est convexe sur } U \text{ ssi} \\ &\forall x, y \in U, \quad \langle \nabla f(y) - \nabla f(x), x - y \rangle \geq 0 \end{aligned}$$

Rq:
Le gradient de f est dit monotone

Optimisation et convexité

■ Convexité

□ *Fonction convexe : en pratique*

- La condition précédente n'est en pratique pas simple à vérifier
- En pratique donc, on préfère utiliser des conditions sur le gradient ou le **hessien (si f est de classe C^2)** :

$$\begin{aligned} &\text{Soit } U \subset \mathfrak{R}^n, \quad f : U \rightarrow \mathfrak{R}, \\ &f \text{ est convexe sur } U \text{ ssi} \\ &\forall x, y \in U, \quad \langle \nabla^2 f(x)(x - y), x - y \rangle \geq 0 \end{aligned}$$

Optimisation et convexité

■ Convexité

□ *Fonction convexe : exemple*

- Montrer la convexité (et même la stricte convexité) de la fonction définie de \mathbb{R} dans \mathbb{R}

$$f(x) = x^2$$

Optimisation et convexité

■ Convexité

□ *Fonction convexe : exemple*

- Montrer la convexité (et même la stricte convexité) de la fonction définie de \mathbb{R} dans \mathbb{R}

$$f(x) = x^2$$

- Les normes sont des fonctions convexes

Optimisation et convexité

■ Concavité

□ *Fonction concave*

Soit $U \subset \mathfrak{R}^n$, et $f : U \rightarrow \mathfrak{R}$,
 f est concave sur U ssi

...

Optimisation et convexité

- **Concavité**
 - *Fonction concave*



Optimisation et convexité

■ Concavité

□ *Fonction concave*

Soit $U \subset \mathbb{R}^n$, et $f : U \rightarrow \mathbb{R}$,
 f est concave sur U ssi
-f est convexe



Optimisation et convexité

■ Théorème 3

□ *Optimalité et convexité*

Soit $U \subset \mathfrak{R}^n$, $u^* \in U$ et $f : U \rightarrow \mathfrak{R}$,
Si f est convexe sur U et admet
un minimum local en u^* **alors**
 f admet aussi un minimum global en u^*

Optimisation et convexité

■ Théorème 4

□ *Optimalité et convexité*


Soit $U \subset \mathfrak{R}^n$, $u^* \in U$ et $f : U \rightarrow \mathfrak{R}$,
Si f est convexe sur U et est au moins C^1 sur U
alors
 f admet un minimum global en u^* **ssi**
$$\nabla f(u^*) = 0$$

Optimisation et convexité

■ Illustration


□ *Optimalité et convexité*

$$x^* = \arg \min(f(x)) \Rightarrow \nabla f(x^*) = 0$$



f est ici différentiable

$$x^* = \operatorname{argmin}(f(x)) \Leftrightarrow \nabla f(x^*) = 0$$



f est ici différentiable
et convexe

Plan

- 1. Introduction
- 2. Formalisation
- 3. Rappels de mathématiques
- 4. Optimisation et convexité
- 5. Classification

Classification

■ **Comment classer les problèmes d'optimisation**

□ M. Minoux 1983

- Classer les problèmes d'optimisation en fonction des caractéristiques mathématiques de la fonction de coût et de celles des contraintes du problème posé (s'il y en a)
- On distinguera alors :
 - *L'optimisation linéaire, quadratique, non-linéaire, convexe*
- Toute classification a ses imperfections... par exemple pour d'autres (dont Guy Cohen) l'optimisation linéaire fait partie de la branche des pb d'optimisation convexe

Classification

■ **1. Optimisation linéaire (ou LP)**

- La fonction de coût et les contraintes sont des fonctions linéaires de la variable x considérée (dans R^n)
- *Exemple en dimension 2:*
 - *On cherche à minimiser la fonction coût J telle que :*

$$\begin{cases} J(x_1, x_2) = ax_1 + bx_2 \\ x_1 \geq 0, x_2 \geq 0 \\ x_1 + x_2 \leq c \end{cases} \quad a, b, c \in \mathfrak{R}$$

Classification

■ 1. Optimisation linéaire (ou LP)

□ Généralisation

- On cherche à minimiser la fonction coût J telle que :

$$\left\{ \begin{array}{l} J(x) = \sum_{i=1}^n c_i x_i \\ \text{avec } \sum_{i=1}^n a_{ij} x_i \leq b_j, \quad j = 1, m \\ \text{et } x_j \geq 0 \end{array} \right.$$

← Contraintes d'inégalités

← Contraintes de signe

Classification

■ 1. *Optimisation linéaire (ou LP)*

□ *Généralisation*

■ *Forme canonique pure:*

$$\begin{cases} J(x) = c^T x \\ Ax \leq b \\ x \geq 0 \end{cases} \quad A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ \vdots & & & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix}$$

Classification

■ **1. Optimisation linéaire (ou LP)**

□ **Avantages**

- *Les fonctions linéaires sont convexes*
- *Un minimum local est donc également globale*
- *Le minimum est unique si la stricte convexité peut-être montrée (souvent le cas)*
- *« Facile » à résoudre en programmation linéaire (méthode du simplexe utilisée depuis les années 40)*


Classification

■ 1. Optimisation linéaire (ou LP)

□ Algorithme du simplexe en dimension 2 (maximisation)

$$J(x, y) = 5x + 7y$$

$$\begin{cases} x + 2y \leq 60 \\ 2y \leq 42 \\ 3x + y \leq 90 \end{cases}$$



Un problème de programmation linéaire

Classification

- **1. Optimisation linéaire (LP)**
 - *Un peu d'histoire*
 - **1900** Début de l'étude mathématique de la convexité (H. Minkowski)
 - **1947** Algorithme du simplexe pour l'optimisation linéaire (G. Dantzig)
 - **1948** Premières applications militaires “recherche opérationnelle”
 - **1970** Analyse convexe (W. Fenchel, J.-J. Moreau, T. Rockafellar)
 - **1994** Algorithme de points intérieurs (Y. Nesterov & A. Nemirovski)

Classification

■ 2. Optimisation Quadratique (QP)

- *La fonction à minimiser q est définie en $x=(x_1, x_2, x_3, \dots, x_n)$ de R^n par la relation matricielle :*

$$q(x) = g^T x + \frac{1}{2} x^T Hx + c$$

avec g un vecteur de \mathfrak{R}^n , $c \in \mathfrak{R}$, et

H une matrice réelle symétrique

de $\mathfrak{R}^n \times \mathfrak{R}^n$

Classification

■ 2. Optimisation Quadratique (QP)

- *La fonction à minimiser q est définie en $x=(x_1, x_2, x_3, \dots, x_n)$ de R^n par la relation matricielle :*

$$q(x) = g^T x + \frac{1}{2} x^T Hx + c$$

- La constante c peut ne pas être prise en compte de par le fait qu'elle n'influe pas sur le problème de minimisation

Classification

- **2. Optimisation Quadratique (QP)**

- *Ou encore sous forme développer en omettant c :*

$$q(x) = \sum_1^n g_i x_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n H_{ij} x_i x_j$$

Classification

- **2. Optimisation Quadratique (QP)**
 - **Convexité :**
 - Une fonction quadratique est convexe **ssi** H est *semi-définie positive*
 - Une fonction quadratique est **strictement** convexe **ssi** H est *définie positive*

Classification

■ **2. Optimisation Quadratique (QP)**

□ *Rappels au cas où 😊 :*

- Une matrice carrée symétrique est définie positive si toutes ses valeurs propres sont strictement positives.
- Une matrice carrée symétrique est semi-définie positive si toutes ses valeurs propres sont positives ou nulles.

Classification

■ 2. *Optimisation Quadratique (QP)*

□ *Rappels (toujours au cas où 😊):*

- Une matrice H symétrique de $R^n \times R^n$ possèdent n valeurs propres λ_j
- On détermine les valeurs propres en résolvant :

$$\det(H - \lambda I) = 0$$

I étant la matrice identité et $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_n)$

Classification

- **2. Optimisation Quadratique (QP)**
 - *Les contraintes du problème d'optimisation*
 - Les m ($m < n$) contraintes sont représentées par des fonctions affines linéaires de la variable x de R^n

Classification

■ **2. Optimisation Quadratique (QP)**

□ *Les contraintes du problème d'optimisation*

- Les m ($m < n$) contraintes sont représentées par des fonctions affines linéaires de la variable x de R^n

■ **Contraintes d'égalité**

$$Ax = b$$

A est une matrice de $R^{m \times n}$ et b un vecteur réel de R^m

Classification

■ 2. **Optimisation Quadratique (QP)**

□ *Les contraintes du problème d'optimisation*

- Les m ($m < n$) contraintes sont représentées par des fonctions affines linéaires de la variable x de R^n

■ **Contraintes d'inégalité**

$$b_l \leq Ax \leq b_h$$

A est une matrice de $R^m \times R^n$ et b_l et b_h deux vecteur réels de R^m

Classification

- **2. Optimisation Quadratique (QP)**
 - *En résumé*

$$J(x^*) = \min \left(g^T x + \frac{1}{2} x^T H x \right)$$

sous contraintes que

$$b_l \leq Ax \leq b_h \text{ ou } Ax = b$$

Classification

■ 2. *Optimisation Quadratique (QP)*

□ *Résolution*


- *Si les contraintes sont des égalités, on retombe sur un problème d'optimisation linéaire*
- *Pour des contraintes de type inégalité, le problème devient NP-complexe... ☹*
 - *Algorithme du gradient conjugué (des extensions),*
 - *Algorithme du gradient projeté,*
 - *Algorithme du simplexe (des extensions).*
 - *Algorithmes de points intérieurs.*

Classification

- **2. Optimisation Quadratique (QP)**
 - *Cas particulier d'un pb QP sans contraintes*
 - *Il s'agit en fait d'un simple problème de moindre carré !*
 - *La solution peut se calculer analytiquement (voir section exemple)*

Classification

■ 3. *Optimisation Convexe*



Classification

- **3. Optimisation Convexe**
 - ***Cas le meilleur !***
 - ***Un formalisme mathématique riche assurant l'existence et l'unicité de la solutions aux problèmes d'optimisation***
 - ***Des algorithmes efficaces (voir chapitre suivant)***

Plan

- 1. Introduction
- 2. Formalisation
- 3. Rappels de mathématiques
- 4. Optimisation et convexité
- 5. Classification
- 6. Exemple : les moindres carrés

Exemple

■ **Les moindres carrés**

- *On se place dans R^n*
- *On dispose d'une variable expliquée (ou réponse) **b de R^n***
- *On dispose d'un ensemble de mesures pouvant se mettre sous la forme d'une matrice de taille $m \times n$ notée A (semi-)définie positive*
- ***On cherche la variable explicative x permettant d'approximer au mieux b au sens de la norme euclidienne (erreur) connaissant A***

Exemple

- **Les moindres carrés**

- *Problème d'optimisation quadratique sans contrainte*

$$J(x^*) = \min_{x \in \mathfrak{R}^n} \|Ax - b\|^2$$

- **Rq:** *les normes étant des fonctions strictement convexes, on est dans un cas « idéal »*

Exemple

- **Les moindres carrés**

- *Solution analytique du problème*

- *J étant strictement convexe, trouver le min de J est équivalent à résoudre :*

$$\nabla J(x^*) = 0$$

- *Résolution ?*

- *Il faut dériver une fonction quadratique du type*

$$f(x) = x^T Ax$$

Exemple

■ **Les moindres carrés**

□ *Solution analytique du problème*

- *Dérivée d'une fonction quadratique de matrice A (forme standard)*

$$\frac{\partial f(x)}{\partial x} = (A + A^T)x$$

- *Développement de J*

$$J(x) = \|Ax - b\|^2 = \|Ax\|^2 - 2\langle Ax, b \rangle + \|b\|^2$$

Exemple

- **Les moindres carrés**

- *Solution analytique du problème*

- *Développement de J*

$$J(x) = \|Ax - b\|^2 = \|Ax\|^2 - 2\langle Ax, b \rangle + \|b\|^2$$

- *Ou encore*

$$J(x) = \|Ax - b\|^2 = x^T A^T A x - 2x^T A^T b + b^T b$$

Exemple

- **Les moindres carrés**
 - *Solution analytique du problème*
 - *Calcul du gradient de J*

$$\nabla J(x) = (A^T A + A A^T) x - 2A^T b + 0 = 2A^T A x - 2A^T b$$

- *Minimum atteint quand le gradient s'annule, soit pour :*

$$A^T A x = A^T b$$

Rq : En statistique, si on fait une hypothèse de gaussianité de l'erreur autour des valeurs réelles, Ax est l'estimateur sans biais du maximum de vraisemblance de b