

# Elements d'Optimisation

Olivier Brun

`brun@laas.fr`

LAAS-CNRS

7 Av. Colonel Roche, 31077 Toulouse, France.

INSA, 2010.

# Outline

- 1 Optimisation Convexe
- 2 Programmation Linéaire
- 3 Programmation Linéaire Mixte
- 4 Dualité

## ● Objectifs

- Rappeler quelques éléments de base de la théorie de l'optimisation.
- La présentation évite de rentrer dans les détails mathématiques et se contente d'introduire quelques notions nécessaires à la bonne compréhension du cours.
- Optimisation convexe, programmation linéaire, programmation linéaire mixte, recherche locale.

# Optimisation Convexe

- Un ensemble  $\mathcal{K} \subset \mathbb{R}^n$  est dit convexe si le segment joignant deux points  $\mathbf{x}, \mathbf{y} \in \mathcal{K}$  appartient à  $\mathcal{K}$

$$\alpha \mathbf{x} + (1 - \alpha) \mathbf{y} \in \mathcal{K} \quad \forall \alpha \in [0, 1], \forall \mathbf{x}, \mathbf{y} \in \mathcal{K}$$

- Exemples : boule unité  $\mathcal{K} = \{\mathbf{x} \in \mathbb{R}^n : \|\mathbf{x}\| \leq 1\}$ , ellipsoïdes, polyèdres,...
- Les ensembles convexes de  $\mathbb{R}$  sont les intervalles.
- L'intersection d'ensembles convexes est un ensemble convexe.


- Etant donné un ensemble convexe  $\mathcal{K} \subset \mathbb{R}^n$ , une fonction  $f(\mathbf{x}) : \mathcal{K} \rightarrow \mathbb{R}$  est dite convexe sur  $\mathcal{K}$  si

$$f(\alpha \mathbf{x} + (1 - \alpha) \mathbf{y}) \leq \alpha f(\mathbf{x}) + (1 - \alpha) f(\mathbf{y}) \quad \forall \alpha \in (0, 1), \forall \mathbf{x}, \mathbf{y} \in \mathcal{K}$$

- On dit que  $f$  est strictement convexe si l'inégalité est stricte.
- Exemple : les fonctions linéaires  $f(\mathbf{x}) = \sum_i c_i x_i$  sont convexes,  $e^{\mathbf{x}}$  est strictement convexe...
- L'addition, la multiplication par un scalaire et l'opérateur max préservent la convexité.

# Fonctions convexes

- **Fonctions convexes** : tout segment  $S$  joignant les points  $(\mathbf{x}, f(\mathbf{x}))$  et  $(\mathbf{y}, f(\mathbf{y}))$  se trouve “au dessus” de la courbe de  $f$ .



- **Problème d'optimisation :**

$$\begin{aligned} & \text{Minimiser} && f(\mathbf{x}) \\ & \text{s.t} && \mathbf{x} \in \mathcal{K} \end{aligned}$$

- **Optimalité :** un point admissible  $\mathbf{x}^* \in \mathcal{K}$  est dit optimal si  $f(\mathbf{x}^*) \leq f(\mathbf{x}), \forall \mathbf{x} \in \mathcal{K}$ .

- On parle d'optimum local si l'inégalité n'est vraie que dans un voisinage de  $\mathbf{x}^*$ .
- Unicité du minimum global si  $f$  strictement convexe.

- **Optimisation convexe :**

- $\mathcal{K}$  est un ensemble fermé et convexe,
- $f$  est convexe et continuellement différentiable sur  $\mathcal{K}$ .
- Tout minimum local est un minimum global.

# Conditions d'optimalité

- Gradient de  $f$  au point  $\mathbf{x}$  :  $\nabla f(\mathbf{x}) = \left( \frac{\partial f}{\partial x_i}(\mathbf{x}) \right)_{i=1, \dots, n}^T$ .
- Produit scalaire des vecteurs  $\mathbf{d}$  et  $\nabla f(\mathbf{x})$  :

$$\mathbf{d}^T \nabla f(\mathbf{x}) = \sum_{i=1}^n \frac{\partial f}{\partial x_i}(\mathbf{x}) d_i$$


- Développement en série de Taylor (premier ordre)

$$\mathbf{y} = \mathbf{x} + \alpha \mathbf{d} \implies f(\mathbf{y}) \approx f(\mathbf{x}) + \alpha \mathbf{d}^T \nabla f(\mathbf{x}) + o(\alpha \mathbf{d})$$

pour toute direction  $\mathbf{d} \in \mathbb{R}^n$  et pour  $\alpha > 0$  suffisamment petit.

## Conditions d'optimalité (2)

- La direction  $\mathbf{d}$  est une direction de
  - maximisation si  $\mathbf{d}$  forme un angle aigu avec  $\nabla f(\mathbf{x})$  :  $\mathbf{d}^T \nabla f(\mathbf{x}) > 0$ .
  - minimisation si  $\mathbf{d}$  forme un angle obtus avec  $\nabla f(\mathbf{x})$  :  $\mathbf{d}^T \nabla f(\mathbf{x}) < 0$ .
- Le gradient est normal aux courbes iso-coûts  $f(\mathbf{x}) = cte$ .




## Conditions d'optimalité (3)

- **Direction admissible** : la direction  $\mathbf{d}$  est admissible en  $\mathbf{x} \in \mathcal{K}$  ssi il existe  $\alpha > 0$  tel que  $\mathbf{y} = \mathbf{x} + \alpha\mathbf{d} \in \mathcal{K}$ .
- **Principe du minimum** :  $\mathbf{x}^* \in \mathcal{K}$  est une solution optimale ssi


$$(\mathbf{y} - \mathbf{x}^*)^T \nabla f(\mathbf{x}^*) \geq 0 \quad \forall \mathbf{y} \in \mathcal{K}$$

- Toute direction admissible  $\mathbf{d} = \mathbf{y} - \mathbf{x}$  est une direction de maximisation, i.e. elle forme un angle aiguë avec le gradient.
  - Cette condition est suffisante grâce à la convexité.
  - Si  $\mathcal{K} = \mathbb{R}^n$ , on retrouve  $\nabla f(\mathbf{x}^*) = 0$ .
- 
- Idée de base des méthodes de direction admissible (cf. cours optimisation non-linéaire du routage).

# Conditions d'optimalité (4)



$\mathbf{x}^* = \text{minimum global.}$



$\mathbf{x}^* \neq \text{minimum global.}$

# Conditions d'optimalité de Karush-Kuhn-Tucker

- L'ensemble  $\mathcal{K}$  des solutions admissibles est défini par :

$$\mathbf{x} \in \mathcal{K} \iff \begin{cases} h_i(\mathbf{x}) = 0 & i = 1, \dots, k \\ g_j(\mathbf{x}) \leq 0 & j = 1, \dots, m \end{cases}$$

## Theorem (Conditions KKT)

*Si  $\mathbf{x}^*$  est un minimum local, il existe des multiplicateurs  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_k) \in \mathbb{R}^k$  et  $\boldsymbol{\lambda} = (\lambda_1, \dots, \lambda_m) \in \mathbb{R}_+^m$  tels que*


$$\begin{aligned} \lambda_j g_j(\mathbf{x}^*) &= 0 \quad j = 1, \dots, m \\ \nabla f(\mathbf{x}^*) &= - \sum_i \mu_i \nabla h(\mathbf{x}^*) - \sum_j \lambda_j \nabla g(\mathbf{x}^*) \end{aligned}$$

- La projection de  $-\nabla f$  sur  $\mathcal{K}$  est le vecteur nul.

# Exemple : routage dans une ferme de serveurs

## ● Un dispatcher centralisé route des jobs vers des serveurs

- Objectif : minimiser la durée moyenne de traitement.
- Taux d'arrivée des jobs  $\bar{\lambda}$  (Poisson).
- Serveur  $j$  : capacité  $r_j$ , coût  $c_j$ /job et trafic  $x_j$ .
- $\frac{c_1}{r_1} \leq \frac{c_2}{r_2} \dots \leq \frac{c_S}{r_S}$
- Modèle M/G/1/PS pour les serveurs.



$$\begin{aligned} \text{Min}_x \quad & \sum_{j \in \mathcal{S}} c_j \frac{x_j}{r_j - x_j} \\ \text{s.t.} \quad & \sum_{j \in \mathcal{S}} x_j = \bar{\lambda} \\ & x_j \geq 0 \quad j \in \mathcal{S} \end{aligned}$$

## Exemple : routage dans une ferme de serveurs (2)

- **Conditions KKT** :  $\exists \mu \in \mathbb{R}_+$  t.q.

$$\frac{\partial f}{\partial x_j}(\mathbf{x}^*) = \frac{c_j}{r_j} \frac{1}{(1 - x_j/r_j)^2} \geq \mu$$

avec égalité ssi  $x_j^* > 0$ .

- **Conclusion** : le routage optimal ne route des jobs que vers les serveurs ayant un coût marginal  $\frac{\partial f}{\partial x_j}(\mathbf{x}^*)$  minimal.

# Exemple : routage dans une ferme de serveurs (3)

## ● Routage optimal :

- L'ensemble des serveurs utilisés par le partage de charge optimal est  $\mathcal{S}^* = \{1, \dots, j^*\}$ , où

$$j^* = \max \left\{ j \in \mathcal{S} \mid \sum_{k=1}^j \sqrt{c_k r_k} > \left( \sum_{k=1}^j r_k - \bar{\lambda} \right) \sqrt{\frac{c_j}{r_j}} \right\}$$

- La charge du serveur  $j \in \mathcal{S}^*$  en utilisant une politique optimale est donnée par,

$$x_j^* = r_j \left( 1 - \sqrt{\frac{c_j}{r_j} \frac{\sum_{k \in \mathcal{S}^*} r_k - \bar{\lambda}}{\sum_{k \in \mathcal{S}^*} \sqrt{c_k r_k}}} \right)$$

tandis que  $x_j^* = 0$  pour  $j \notin \mathcal{S}^*$ .

# Programmation Linéaire

- Un programme linéaire est un problème d'optimisation convexe de la forme

$$\begin{aligned} &\text{Minimiser} && z = \sum_i c_i x_i \\ &\text{s.t} && \\ &&& \sum_i a_{ji} x_i \leq b_j \quad j = 1, \dots, m \end{aligned}$$


ou sous forme matricielle

$$\begin{aligned} &\text{Minimiser} && z = \mathbf{c}^T \mathbf{x} \\ &\text{s.t} && \mathbf{A} \mathbf{x} \leq \mathbf{b} \end{aligned}$$

- $\sum_i a_{ji} x_i = b_j$  est équivalent à  $\sum_i a_{ji} x_i \leq b_j$  et  $-\sum_i a_{ji} x_i \leq -b_j$ .


# Propriétés fondamentales (1)

$$\begin{array}{ll} \text{Max} & z = x_1 + 3x_2 \\ \text{s.t} & \\ & -x_1 + x_2 \leq 1 \\ & x_1 + x_2 \leq 2 \\ & x_1 \geq 0, x_2 \geq 0 \end{array}$$




## Propriétés fondamentales (2)

- Ensemble des solutions : intersection des demi-plans satisfaisant l'inégalité linéaire.
- Point numérotés : points extrêmes.
- Les courbes iso-coûts  $c = x_1 + 3x_2$  sont // les unes aux autres.



## Propriétés fondamentales (3)

- La valeur max de  $z$  correspond à la plus grande valeur de  $c$  pour laquelle la ligne iso-coût a au moins un point commun avec l'ensemble des solutions :  $c = 5$ ,  $x_1 = \frac{1}{2}$ ,  $x_2 = \frac{3}{2}$ .



### Propriété fondamentale

L'optimum d'un PL est toujours atteint en un point extrême.

- **Quatre possibilités**

- **Pas de solution** : si on remplace  $x_1 + x_2 \leq 2$  par  $x_1 + x_2 \leq -1$  l'ensemble solution est vide.
- **Solution non bornée** : si on enlève  $x_1 + x_2 \leq 2$ , alors  $\max z = +\infty$ .
- **Solution unique** : elle correspond à un point extrême.
- **Infinité de solution** : si on remplace  $z = x_1 + 3x_2$  par  $z = 2(x_1 + x_2)$  alors les lignes iso-coûts sont parallèles à la contrainte  $x_1 + x_2 = 2$  et le maximum est atteint en tout point de ce segment.

- **Généralisation en dimension  $n$  de ce qu'on a vu dans  $\mathbb{R}^2$** 
  - Phase 1 : obtention d'une solution admissible de base (si existence)
  - Phase 2 : détermination de l'optimum global.
- **Méthode itérative :**
  - Visite consécutivement des solutions de base (points extrémaux du polyèdre),
  - Diminue le coût à chaque itération,
  - Identifie le minimum global quand il est atteint.
- **Algorithmes implémentés dans de nombreux solveurs linéaires :** CPLEX, Xpress MP, Ip solve, matlab, etc.
- **Extrêmement efficace :** on peut résoudre des problèmes avec des milliers de variables et de contraintes en des temps calcul raisonnables.

# Programmation Linéaire Mixte

- Exemple des PL mixtes avec variables 0-1 :

$$\text{Minimiser} \quad z = \sum_{i=1}^n c_i x_i$$

s.t

$$\sum_i a_{ij} x_i \leq b_j \quad j = 1, \dots, m$$

$$x_i \in \{0, 1\} \quad i = 1, \dots, k$$

$$x_i \geq 0 \quad i = k + 1, \dots, n$$

- Solution partielle :

- $N_0 \subset \{1, \dots, k\}$  : variables binaires valant 0,
- $N_1 \subset \{1, \dots, k\}$  : variables binaires valant 1,
- $N_U \subset \{1, \dots, k\}$  : variables binaires non fixées.

- Borne inférieure  $z^*$  sur le coût d'une solution partielle obtenue en résolvant le problème relaxé :


$$\begin{aligned} & \text{Minimiser} && z = \sum_{i=1}^n c_i x_i \\ & \text{s.t} && \\ & && \sum_i a_{ij} x_i \leq b_j \quad j = 1, \dots, m \\ & && x_i \geq 0 \quad i = k+1, \dots, n \\ & && 0 \leq x_i \leq 1 \quad i \in N_U \\ & && x_i = 0 \quad i \in N_0 \\ & && x_i = 1 \quad i \in N_1 \end{aligned}$$

- Toute solution complète  $\mathbf{x}$  obtenue à partir de la solution partielle  $(N_0, N_1, N_U)$  en fixant les valeurs des variables  $j \in N_U$  à 0 ou à 1 aura un coût supérieur ou égal à  $z^*$ .

# Branch and Bound (1)

## ● Principe :

- Explorer l'arbre représentant l'ensemble des solutions,
- Mettre à jour la borne sup quand une solution complète améliorante est découverte,
- Calculer une borne inférieure en chaque noeud et élaguer l'arbre si  $z^* \geq z^{best}$ .



## ● Algorithme du Branch-and-Bound :


```
1: procedure BRANCH-AND-BOUND( $(N_U, N_0, N_1)$ )
2:   LinearProgramming( $(N_U, N_0, N_1, \mathbf{x}, z^*)$ )
3:   if  $N_U = \emptyset$  or  $x_i \in \{0, 1\} \forall i \in N_U$  then
4:     if  $z^* < z^{best}$  then
5:        $z^{best} = z^*$  et  $\mathbf{x}^{best} = \mathbf{x}$ 
6:     end if
7:   else ▷ au moins un  $x_i$  non binaire
8:     if  $z^* \geq z^{best}$  then
9:       return ▷ bounding
10:    else ▷ branching
11:      Choisir  $i \in N_U$  tel que  $x_i \neq 0, 1$ 
12:      Branch-and-Bound( $N_U - i, N_0 \cup \{i\}, N_1$ )
13:      Branch-and-Bound( $N_U - i, N_0, N_1 \cup \{i\}$ )
14:    end if
15:  end if
16: end procedure
```

## Branch and Bound (3)

- Généralisation à des variables entières.
- Implémenté par de nombreux solveurs : CPLEX, Xpress MP, Ip solve, etc.
- Performances limitées à des problèmes de "petites" tailles :
  - Beaucoup de temps passé pour prouver l'optimalité,
  - Incontournable pour évaluer des approximations.
- La borne inférieure obtenue par relaxation linéaire est souvent grossière :
  - L'idée de base du Branch-and-Cut est d'améliorer la borne inférieure en ajoutant des contraintes vérifiées par toute solution entière mais excluant une partie des solutions continues (enveloppe convexe).

# Branch and Cut (1)

Max  $z = 10x_1 + 11x_2$   
s.t  
 $10x_1 + 12x_2 \leq 59$   
 $x_1, x_2 \in \mathbb{N}$



- Problème relaxé (PL) :  $x^* = (5.9, 0)$  et  $z^* = 59$ .
  - En arrondissant :  $x^* = (5, 0)$  et  $z^* = 50$ .
- Problème discret (PLNE) :  $x^* = (1, 4)$  et  $z^* = 54$ .

## Branch and Cut (2)

- Polyèdre convexe contenant toutes les solutions entières :


$$x_1 + x_2 \leq 5 \quad 0 \leq x_2 \leq 4 \quad x_1 \geq 0$$

$$\begin{aligned} \text{Max } z &= 10x_1 + 11x_2 \\ \text{s.t} \end{aligned}$$

$$x_1 + x_2 \leq 5$$

$$0 \leq x_2 \leq 4$$

$$x_1 \geq 0$$



- Borne inférieure :  $x^* = (1, 4)$  et  $z^* = 54$ .

# Dualité

- On considère le problème suivant :

Minimiser  $f(\mathbf{x})$

s.t

$$h_i(\mathbf{x}) = 0 \quad i = 1, \dots, k$$

$$g_j(\mathbf{x}) \leq 0 \quad j = 1, \dots, m$$

$$\mathbf{x} \in \mathcal{K}$$

- Lagrangien :

$$L(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\lambda}) = f(\mathbf{x}) + \sum_i \mu_i h_i(\mathbf{x}) + \sum_j \lambda_j g_j(\mathbf{x}) \quad \boldsymbol{\mu} \in \mathbb{R}^k, \boldsymbol{\lambda} \in \mathbb{R}_+^m$$

- **Fonction duale :**

$$W(\boldsymbol{\mu}, \boldsymbol{\lambda}) = \min_{\mathbf{x} \in \mathcal{K}} L(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\lambda}) \quad \boldsymbol{\mu} \in \mathbb{R}^k, \boldsymbol{\lambda} \in \mathbb{R}_+^m$$

$$\text{Dom}(W) = \left\{ (\boldsymbol{\mu}, \boldsymbol{\lambda}) : \boldsymbol{\mu} \in \mathbb{R}^k, \boldsymbol{\lambda} \in \mathbb{R}_+^m, \min_{\mathbf{x} \in \mathcal{K}} L(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\lambda}) > -\infty \right\}$$

- **Problème dual :**

$$\begin{aligned} &\text{Maximiser} && W(\boldsymbol{\mu}, \boldsymbol{\lambda}) \\ &\text{s.t} && \boldsymbol{\mu} \in \mathbb{R}^k, \boldsymbol{\lambda} \in \mathbb{R}_+^m \end{aligned}$$

- **Pour un problème d'optimisation convexe :**

- La fonction duale  $W(\mu, \lambda)$  est concave et son domaine convexe,
- Si le primal et le dual sont faisables,  $f(\mathbf{x}^*) = W(\mu^*, \lambda^*)$ ,
- Si le primal n'est pas borné (par en dessous), le dual est infaisable. Réciproquement, si le dual n'est pas borné (par en dessus), le primal est infaisable
- A chaque solution optimale  $(\mu^*, \lambda^*)$  du dual correspond une solution optimale du primal  $\mathbf{x}^*$ , et réciproquement.
- La solution duale  $(\mu^*, \lambda^*)$  correspond aux multiplicateurs de Lagrange des conditions KKT.