

# Elements d'Optimisation Mathématique

Olivier Brun

`brun@laas.fr`

LAAS-CNRS

7 Av. Colonel Roche, 31077 Toulouse, France.

INSA, 2024.

# 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, dualité en programmation linéaire.

- **Problème d'optimisation :**

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

- Maximiser  $f(\mathbf{x})$  est équivalent à minimiser  $-f(\mathbf{x})$
- $f(x)$  : fonction objectif,
- $\mathcal{K}$  : ensemble des solutions admissibles
- **Optimalité** :  $\mathbf{x}^* \in \mathcal{K}$  est optimal si  $f(\mathbf{x}^*) \leq f(\mathbf{x}), \forall \mathbf{x} \in \mathcal{K}$ .
  - Optimum local si l'inégalité n'est vraie que dans un voisinage de  $\mathbf{x}^*$ .
- Besoin d'hypothèses : différentiabilité et convexité.

# 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  $f(\mathbf{x}^*) \leq f(\mathbf{x}), \forall \mathbf{x} \in \mathcal{K}$ .
  - 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.

# Gradient et matrice hessienne

- 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  $\nabla f(\mathbf{x})$  :

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

- Matrice hessienne de  $f$  en  $\mathbf{x}$  :  $\mathbf{H}(\mathbf{x}) = \left( \frac{\partial^2 f}{\partial x_i \partial x_j}(\mathbf{x}) \right)_{i=1, j}$
- $f$  est convexe ssi  $H$  est semi-définie positive ( $\mathbf{x}^T \mathbf{H} \mathbf{x} \geq 0$ )
- Exemple :  $f(x_1, x_2) = -\log(1 - x_1 - x_2) - \log(x_1) - \log(x_2)$

# Conditions d'optimalité

- Développement en série de Taylor (premier ordre)

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


pour toute direction  $\mathbf{d} \in \mathbb{R}^n$ .

- Conséquence (pour  $\alpha > 0$  suffisamment petit) :

$$f(\mathbf{y}) < f(\mathbf{x}) \iff \mathbf{d}^T \nabla f(\mathbf{x}) < 0$$

## 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 aigu 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

$$\nabla f(\mathbf{x}^*) = - \sum_i \mu_i \nabla h_i(\mathbf{x}^*) - \sum_j \lambda_j \nabla g_j(\mathbf{x}^*)$$


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

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

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

# Exemple

## ● Problème de routage sur deux liens



$$\text{Min}_x \quad f(x_1, x_2) = c_1\phi(x_1) + c_2\phi(x_2)$$

s.t.

$$x_1 + x_2 = r$$

$$x_1 \geq 0, x_2 \geq 0$$

- $h(x_1, x_2) = x_1 + x_2 - r = 0$  et  $g_i(x_1, x_2) = -x_i \leq 0, i = 1, 2$
- Il existe  $\mu, \lambda_1 \geq 0$  et  $\lambda_2 \geq 0$

$$\frac{\partial f}{\partial x_i}(\mathbf{x}^*) = -\mu \frac{\partial h}{\partial x_i}(\mathbf{x}^*) - \lambda_1 \frac{\partial g_1}{\partial x_i}(\mathbf{x}^*) - \lambda_2 \frac{\partial g_2}{\partial x_i}(\mathbf{x}^*), \quad i = 1, 2$$

ce qui donne, en posant  $\mu' = -\mu, c_i\phi'(x_i^*) \geq \mu' + \lambda_i$ .

# Exemple

- On sait aussi que  $\lambda_i g_i(x^*) = -\lambda_i x_i^* = 0$  et donc

$$x_i^* > 0 \text{ si et seulement si } \lambda_i = 0$$

- On conclut que  $c_i \phi'(x_i^*) \geq \mu'$  avec égalité ssi  $x_i^* > 0$ .

- En supposant  $c_1 < c_2$  :

- La solution optimale est  $x_1^* = r, x_2^* = 0$  si

$$c_2 \phi'(0) > c_1 \phi'(r)$$

- Sinon, la solution optimale est obtenue en résolvant

$$c_1 \phi'(x_1^*) = c_2 \phi'(r - x_1^*)$$

# Programmation Linéaire

# Programmation Linéaire

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

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

s.t

$$\sum_{i=1}^n a_{ji} x_i \geq b_j \quad j = 1, \dots, m,$$

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

ou sous forme matricielle

$$\text{Minimiser } z = \mathbf{c}^T \mathbf{x}$$

$$\text{s.t } \mathbf{A} \mathbf{x} \geq \mathbf{b}, \mathbf{x} \geq \mathbf{0}.$$

# Forme standard

- Maximiser  $\sum_{i=1}^n c_i x_i$  est équivalent à minimiser  $-\sum_{i=1}^n c_i x_i$ .
- Une contrainte d'égalité  $\sum_i a_{ji}x_i = b_j$  est équivalente à

$$\sum_i a_{ji}x_i \leq b_j,$$
$$-\sum_i a_{ji}x_i \leq -b_j.$$


- Si la variable  $x_i$  peut être négative, on peut écrire

$$x_i = x_i^+ - x_i^-$$

avec  $x_i^+ \geq 0$  et  $x_i^- \geq 0$ .


# 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 extrémaux.
- 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 extrémal.

- **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 extrémal.
- **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.

# La méthode du Simplex

- **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, Gurobi, lp 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 :

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

- 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

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


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

- 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, Gurobi, 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)

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



- 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 :

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


$$\text{Max } z = 10x_1 + 11x_2$$

s.t

$$x_1 + x_2 \leq 5$$

$$0 \leq x_2 \leq 4$$

$$x_1 \geq 0$$



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

# Dualité

# Dualité (1)

- Problème **primal** :

$$\text{Minimiser } z = 6x_1 + 4x_2 + 2x_3$$

s.t

$$4x_1 + 2x_2 + x_3 \geq 5 \quad (1)$$

$$x_1 + x_2 \geq 3 \quad (2)$$

$$x_2 + x_3 \geq 4 \quad (3)$$

$$x_i \geq 0 \quad i = 1, 2, 3.$$

- **Bornes inférieures sur la valeur optimale  $z^*$**  :

- Avec (1) :  $z = 6x_1 + 4x_2 + 2x_3 \geq 4x_1 + 2x_2 + x_3 \implies z^* \geq 5$

- Avec (1) et (2) :

$$z \geq (4x_1 + 2x_2 + x_3) + 2(x_1 + x_2) \implies z^* \geq 5 + 2 \times 3 = 11$$

- Avec (1), (2) et (3) :

$$z \geq (4x_1 + 2x_2 + x_3) + (x_1 + x_2) + (x_2 + x_3) \implies z^* \geq 5 + 3 + 4 = 12$$

## Dualité (2)

- **Généralisation** : en multipliant (1) par  $y_1 \geq 0$ , (2) par  $y_2 \geq 0$  et (3) par  $y_3 \geq 0$ , on obtient  $z^* \geq 5y_1 + 3y_2 + 4y_3$  si la condition suivante est vérifiée :

$$\begin{aligned}6x_1 + 4x_2 + 2x_3 &\geq y_1(4x_1 + 2x_2 + x_3) + y_2(x_1 + x_2) + y_3(x_2 + x_3) \\ &= x_1(4y_1 + y_2) + x_2(2y_1 + y_2 + y_3) + x_3(y_1 + y_3)\end{aligned}$$

- Problème **dual** :

$$\text{Maximiser } w = 5y_1 + 3y_2 + 4y_3$$

s.t

$$4y_1 + y_2 \leq 6$$

$$2y_1 + y_2 + y_3 \leq 4$$

$$y_1 + y_3 \leq 2$$

$$y_i \geq 0 \quad i = 1, 2, 3.$$

- Borne inférieure :  $z^* \geq w^*$

## PRIMAL

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

s.t

$$\sum_{i=1}^n a_{ij} x_i \geq b_j \quad j = 1, \dots, m,$$

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

## DUAL

$$\text{Max } w = \sum_{j=1}^m b_j y_j$$

s.t

$$\sum_{j=1}^m a_{ji} y_j \leq c_i \quad i = 1, \dots, n,$$

$$y_j \geq 0 \quad j = 1, \dots, m.$$

# Dualité (4)

- **Dualité faible** : Si  $\mathbf{x}$  est une solution admissible du primal et  $\mathbf{y}$  une solution admissible du dual, alors  $\sum_{i=1}^n c_i x_i \geq \sum_{j=1}^m b_j y_j$ .
- **Dualité forte** : Si le primal et le dual sont faisables, alors pour toute solution optimale  $\mathbf{x}^*$  du primal et pour toute solution optimale  $\mathbf{y}^*$  du dual, on a  $\sum_{i=1}^n c_i x_i^* = \sum_{j=1}^m b_j y_j^*$ .
- Exemple : la solution optimale du primal est  $x_1^* = 0, x_2^* = 3$  et  $x_3^* = 1$ . La solution optimale du dual est  $y_1^* = 0, y_2^* = 2$  et  $y_3^* = 2$ . On a bien  $6x_1^* + 4x_2^* + 2x_3^* = 14 = 5y_1^* + 3y_2^* + 4y_3^*$
- Conditions de complémentarité :

$$x_i^* > 0 \implies \sum_j a_{j,i} y_j^* = c_i,$$

$$y_j^* > 0 \implies \sum_i a_{j,i} x_i^* = b_j.$$