

# OPTIMISATION ET CONTRÔLE

Grégoire Allaire  
Département de mathématiques appliquées  
Ecole Polytechnique

## Programmation linéaire

- 1 Etude théorique
- 2 Algorithme du simplexe.
- 3 Algorithme des points intérieurs.
- 4 Dualité.
- 5 Initiation à la programmation linéaire en nombre entiers.

# 1 - Etude théorique

On appelle **programme linéaire** un problème d'optimisation pour lequel la fonction objectif et les contraintes sont affines

$$(LP) \quad \inf_{\tilde{x} \in \mathbb{R}^{\tilde{n}} \text{ tel que } \tilde{A}\tilde{x} \geq \tilde{b}, \tilde{A}'\tilde{x} = \tilde{b}'}} \tilde{c} \cdot \tilde{x}$$

avec des matrices  $\tilde{A}, \tilde{A}'$  et des vecteurs  $\tilde{b}, \tilde{b}', \tilde{c}$ .

**Lemme.** Tout programme linéaire (LP) peut se mettre sous la **forme standard**

$$(SLP) \quad \inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x,$$

où  $A$  est une matrice  $m \times n$  (avec  $\text{rg}(A) = m$ ),  $b \in \mathbb{R}^m$ ,  $c \in \mathbb{R}^n$ .

**Preuve.** On introduit des variables d'écart (slack variables)  $y \geq 0$

$$\tilde{A}\tilde{x} \geq \tilde{b} \Leftrightarrow \left( \tilde{A}\tilde{x} = \tilde{b} + y \text{ et } y \geq 0 \right)$$

On décompose  $\tilde{x} = \tilde{x}^+ - \tilde{x}^-$ ,  $\tilde{x}^+ = \max(\tilde{x}, 0)$ ,  $\tilde{x}^- = \max(-\tilde{x}, 0)$ .

On élimine les contraintes redondantes pour avoir  $\text{rg}(A) = m$ .



# Définitions (et vocabulaire)

Désormais on se limite aux programmes linéaires **standards**.

1) L'ensemble  $X_{ad}$  des vecteurs de  $\mathbb{R}^n$  qui satisfont les contraintes

$$X_{ad} = \{x \in \mathbb{R}^n \text{ tel que } Ax = b, x \geq 0\},$$

est l'ensemble des **solutions admissibles** (c'est un polyèdre convexe).  
(Polyèdre = intersection finie de demi-espaces.)

2) Un point de minimum de

$$\inf_{x \in X_{ad}} c \cdot x$$


est appelé **solution optimale**.

3) On appelle **sommet** ou point extrémal de  $X_{ad}$  tout point  $\bar{x} \in X_{ad}$  qui ne peut pas se décomposer en une combinaison convexe de deux autres points de  $X_{ad}$ , c'est-à-dire que, s'il existe  $y, z \in X_{ad}$  et  $\theta \in ]0, 1[$  tels que  $\bar{x} = \theta y + (1 - \theta)z$ , alors  $y = z = \bar{x}$ .  
Ce sont les sommets (géométriques) du polyèdre.



# Exemple simple: polyèdre


$$\begin{aligned} \min \quad & x_1 + 4x_2 + 2x_3 \\ & x_1 \geq 0, x_2 \geq 0, x_3 \geq 0 \\ & 2x_1 + x_2 + 3x_3 = 6 \end{aligned}$$



$X_{ad}$  est un polyèdre, ici un triangle plat (en gris) qui a 3 sommets.

# Intuition géométrique: importance des sommets

$$\begin{aligned} \min \quad & x_1 + 4x_2 + 2x_3 \\ & x_1 \geq 0, x_2 \geq 0, x_3 \geq 0 \\ & 2x_1 + x_2 + 3x_3 = 6 \end{aligned}$$



Pour minimiser on **balaie** l'espace  $\mathbb{R}^3$  avec des plans **parallèles**  $x_1 + 4x_2 + 2x_3 = v$  en augmentant  $v$  à partir de  $-\infty$ : on finit par toucher  $X_{ad}$  et atteindre le minimum. Autrement dit, **un des sommets du triangle  $T$  est un point de minimum.**

**Lemme.** Il existe au moins une solution optimale du programme linéaire standard (SLP) si et seulement si la valeur du minimum est finie

$$-\infty < \inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x < +\infty.$$

**Lemme.** S'il existe une solution optimale du programme linéaire, alors il existe une solution optimale qui est un **sommet du polyèdre**.


**Preuve (géométrique).** Faire un dessin:  $X_{ad}$  est l'intersection du quadrant  $\mathbb{R}_+^n$  par un sous-espace affine (voir transparent suivant).

**Preuve (analytique).** Voir un peu plus loin.



# Preuve géométrique

Dans le sous-espace affine  $Ax = b$ ,  $X_{ad}$  ressemble à un des 3 cas:



L'ensemble  $X_{ad}$  n'est pas forcément borné. Il existe une solution optimale (pas toujours unique mais l'une d'entre elles est un sommet) dans les deux cas à gauche mais à droite  $\inf = -\infty$ .



# Principe de résolution

Si un programme linéaire a une valeur minimum finie, alors il existe une solution optimale qui est un sommet de  $X_{ad}$ .

- $X_{ad}$  a un nombre **fini** de sommets.
- Il suffit de tester la valeur de  $c \cdot x$  sur ce nombre fini de sommets !
- Malheureusement le nombre de sommets est **exponentiel** en  $n, m$ . (Cf. le cas du cube en dimension  $d$  qui a  $2^d$  sommets.)
- L'**algorithme du simplexe** de Dantzig énumère intelligemment l'ensemble des sommets en faisant décroître la fonction  $c \cdot x$ .



George Dantzig

(1914-2005)

# Existence d'une solution optimale

**Lemme.** Il existe au moins une solution optimale du programme linéaire standard si et seulement si la valeur du minimum est finie

$$-\infty < \inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x < +\infty.$$

**Preuve (analytique).** Si  $X_{ad} = \{x \in \mathbb{R}^n \text{ t.q. } Ax = b, x \geq 0\}$  est borné, alors le minimum est atteint puisque  $X_{ad}$  est fermé. Si  $X_{ad}$  n'est pas borné, on utilise le Lemme de Farkas pour montrer que le cône suivant est fermé

$$C = \left\{ \sum_{i=1}^n x_i \mathcal{A}_i \text{ avec } x_i \geq 0 \right\} \quad \text{avec} \quad \mathcal{A} = \begin{pmatrix} c^* \\ A \end{pmatrix}$$

et  $\mathcal{A}_i$  les colonnes de la matrice  $\mathcal{A}$ . Soit  $(x^k)_{k \geq 1} \in X_{ad}$  une suite minimisante. Si le minimum est fini, la suite  $\mathcal{A}x^k = (c \cdot x^k, b)^*$  est bornée dans  $C$ , qui est fermé, et converge donc vers une limite  $\mathcal{A}x^* \in C$ , ce qui prouve que  $x^* \in X_{ad}$  est un point de minimum. (On n'a pas prouvé que  $x^k$  converge vers  $x^*$ ...)



# Rappel sur le Lemme de Farkas

Dans la démonstration du Lemme 5.2.19 de Farkas, il est démontré par récurrence sur le nombre  $n$  de vecteurs  $\mathcal{A}_i$  que le cône

$$C = \left\{ \sum_{i=1}^n x_i \mathcal{A}_i \text{ avec } x_i \geq 0 \right\}$$

est fermé (sans aucune hypothèse sur les vecteurs  $\mathcal{A}_i$ ). On applique ce résultat aux colonnes  $\mathcal{A}_i$  de la matrice  $\mathcal{A} = \begin{pmatrix} c^* \\ A \end{pmatrix}$  de taille  $(m+1) \times n$ .

**Remarque.** On vient de démontrer qu'il existe une solution optimale  $x^* \in X_{ad}$ . Il reste à donner une démonstration analytique de l'existence d'une solution optimale qui soit un **sommet du polyèdre**  $X_{ad}$ . Pour cela on introduit quelques notations.



## Définition.

- On appelle **base** de  $X_{ad}$  une base  $B$  de  $\mathbb{R}^m$  formée de  $m$  colonnes de  $A$ . Après permutation de ses colonnes on écrit

$$A = (B, N), \quad x = (x_B, x_N), \quad Ax = Bx_B + Nx_N.$$

avec  $x_B \in \mathbb{R}^m$  **variables de base**,  $x_N \in \mathbb{R}^{n-m}$  **variables hors base**.

- Dimensions:  $A$  est une matrice  $m \times n$ ,  $B$  une matrice  $m \times m$  et  $N$  une matrice  $m \times (n - m)$ .
- Une **solution basique** (ou de base) est  $x \in X_{ad}$  tel que  $x_N = 0$ . Autrement dit,  $(x_B, 0)$  est une solution basique si  $Bx_B = b$  et  $x_B \geq 0$ .

**Lemme.** Les sommets du polyèdre  $X_{ad}$  sont exactement les solutions basiques.



**Preuve.** Si  $x \in X_{ad}$  est une **solution basique**, alors  $x = (x_B, x_N)$  avec  $Bx_B = b$  et  $x_N = 0$ . Supposons qu'il existe  $0 < \theta < 1$  et  $y, z \in X_{ad}$  tels que  $x = \theta y + (1 - \theta)z$ . Alors

$$0 = \theta y_N + (1 - \theta)z_N \text{ et } y \geq 0, z \geq 0 \Rightarrow y_N = z_N = 0.$$

On en déduit  $By_B = Bz_B = b$ , ce qui implique  $x_B = y_B = z_B$ .  
Donc  $x$  est un **sommet** de  $X_{ad}$ .

**Réciproquement**, si  $x$  est un **sommet** de  $X_{ad}$ , comme  $x \geq 0$ , après réarrangement on a  $x = (x_1, \dots, x_k, 0, \dots, 0)$  avec  $x_1, \dots, x_k > 0$  et  $b = \sum_{i=1}^k x_i a_i$  où les  $(a_i)$  sont les colonnes de  $A$ . Alors  $x$  est une solution basique si  $(a_1, \dots, a_k)$  est libre dans  $\mathbb{R}^m$  (on complète pour avoir une base  $B$ ). Si cette famille est liée, il existe  $y \neq 0$  tel que  $\sum_{i=1}^k y_i a_i = 0$  et on fixe  $y_{k+1} = \dots = y_n = 0$ . Comme  $x_1, \dots, x_k > 0$ , il existe  $\epsilon > 0$  tel que  $(x + \epsilon y) \in X_{ad}$  et  $(x - \epsilon y) \in X_{ad}$ . Le fait que  $x = (x + \epsilon y)/2 + (x - \epsilon y)/2$  contredit le caractère extrémal de  $x$ , donc  $x$  est une **solution basique**.



# Existence d'un sommet optimal

**Proposition.** S'il existe une solution optimale, alors au moins une solution optimale est un **sommet du polyèdre**.

**Preuve (analytique).** Soit  $x \in X_{ad}$  une solution optimale.

Comme  $x \geq 0$ , après réarrangement on a  $x = (x_1, \dots, x_k, 0, \dots, 0)$  avec  $x_1, \dots, x_k > 0$  et

$$b = \sum_{i=1}^k x_i a_i \quad \text{avec } (a_i) \text{ les colonnes de } A.$$

Si la famille  $(a_1, \dots, a_k)$  est libre dans  $\mathbb{R}^m$ , alors  $x$  est une **solution optimale basique**. Si  $(a_1, \dots, a_k)$  est lié, alors il existe  $y \neq 0$  tel que

$$\sum_{i=1}^k y_i a_i = 0 \quad \text{et} \quad (y_{k+1}, \dots, y_n) = 0.$$

Comme  $x_1, \dots, x_k > 0$ , il existe  $\epsilon > 0$  tel que  $(x \pm \epsilon y) \in X_{ad}$ .

Comme  $x$  est un point de minimum, on a nécessairement

$$c \cdot x \leq c \cdot (x \pm \epsilon y),$$

c'est-à-dire  $c \cdot y = 0$ .

# Fin de la preuve de la proposition

On définit une famille  $z_\epsilon = x + \epsilon y$ , paramétrée par  $\epsilon \in \mathbb{R}$ , qui vérifie

$$Az_\epsilon = b \quad \text{et} \quad c \cdot z_\epsilon = c \cdot x.$$

En partant de  $\epsilon = 0$ , si on augmente ou on diminue  $\epsilon$ ,  $z_\epsilon$  reste dans l'ensemble  $X_{ad}$  jusqu'à une valeur  $\epsilon_0$  au delà de laquelle la contrainte  $z_\epsilon \geq 0$  est violée.

Autrement dit,  $z_{\epsilon_0} \in X_{ad}$  possède au plus  $(k - 1)$  composantes non nulles et est solution optimale.

On répète l'argument précédent avec  $x = z_{\epsilon_0}$  et une famille de  $(k - 1)$  colonnes  $(a_j)$ . A force de diminuer la taille de cette famille, on obtient finalement une famille libre et une solution optimale basique.



# Condition d'optimalité d'une solution basique

**Proposition.** Soit une solution basique  $\bar{x}$  pour une base  $B$ , supposée **non dégénérée**, c.-à-d.  $\bar{x}_B = B^{-1}b > 0$ . Alors  $\bar{x}$  est optimal **si et seulement si** le **vecteur des coûts réduits** est positif

$$\tilde{c}_N = c_N - N^*(B^{-1})^*c_B \geq 0.$$

**Remarque.** Si la solution basique  $\bar{x}$  est dégénérée,  $\bar{x}_B = B^{-1}b \geq 0$ , alors la condition  $\tilde{c}_N \geq 0$  est seulement **suffisante** pour que  $\bar{x}$  soit optimal.

**Preuve.** On décompose  $x = (x_B, x_N)$  et  $c = (c_B, c_N)$ . Pour tout  $x \in X_{ad}$ ,  $x_B = B^{-1}(b - Nx_N)$  et, comme  $\bar{x} = (B^{-1}b, 0)$ , on a

$$c \cdot x - c \cdot \bar{x} = c_B \cdot B^{-1}(b - Nx_N) + c_N \cdot x_N - c_B \cdot B^{-1}b = \tilde{c}_N \cdot x_N.$$

Si  $\tilde{c}_N \geq 0$ , alors  $\bar{x}$  est optimal car

$$c \cdot x - c \cdot \bar{x} = \tilde{c}_N \cdot x_N \geq 0 \quad \text{puisque } x_N \geq 0.$$

La condition est donc toujours **suffisante**.



# Condition d'optimalité d'une solution basique (fin)

**Réciproquement**, on suppose que  $\exists i$  tel que  $(\tilde{c}_N \cdot e_i) < 0$ .

Pour  $\epsilon > 0$  on définit  $x(\epsilon) = (x_B(\epsilon), x_N(\epsilon))$  par

$$x_N(\epsilon) = \epsilon e_i \quad \text{et} \quad x_B(\epsilon) = B^{-1}(b - Nx_N(\epsilon)).$$

A cause de l'hypothèse de **non-dégénérescence**,  $B^{-1}b > 0$ , on a bien  $x(\epsilon) \geq 0$  et  $x(\epsilon) \in X_{ad}$  pour  $\epsilon$  petit.

Comme  $x(0) = \bar{x}$ , on en déduit

$$c \cdot x(\epsilon) = c \cdot x(0) + \epsilon(\tilde{c}_N \cdot e_i) < c \cdot \bar{x},$$

ce qui montre que  $\bar{x}$  n'est pas optimal. La condition est donc **nécessaire**.



On utilise la condition d'optimalité et le coût réduit.

- On part d'un sommet  $x^0$ , ou solution basique initiale, associée à une base  $B^0$ .
- A l'itération  $k \geq 0$ , on passe d'un sommet  $x^k$  à un nouveau sommet  $x^{k+1}$  en étudiant le **coût réduit**  $\tilde{c}_N^k$ :
  - 1 Si  $\tilde{c}_N^k \geq 0$ , alors  $x^k$  est optimal et on a convergé !
  - 2 S'il existe  $i$  tel que  $\tilde{c}_N^k \cdot e_i < 0$ , alors on bouge et on change une colonne de la base  $B^k$  pour obtenir une nouvelle base  $B^{k+1}$  et diminuer le coût

$$c \cdot x^{k+1} \leq c \cdot x^k.$$

La décroissance est stricte si  $x^k$  est non dégénérée (cf. Proposition précédente).

**Remarque.**  $X_{ad}$  a un nombre fini (exponentiel) de sommets mais l'algorithme du simplexe n'en visite qu'un petit nombre en diminuant le coût.

# Algorithme du simplexe

**Initialisation:**  $x^0$  solution basique associée à la base  $B^0$ .

**Itérations pour  $k \geq 0$ :** pour la base  $B^k$  on calcule le coût réduit

$$\tilde{c}_N^k = c_N^k - (N^k)^*(B^{k-1})^*c_B^k.$$

Si  $\tilde{c}_N^k \geq 0$ , alors  $x^k$  est optimal.

Sinon, **il existe  $i$**  tel que  $\tilde{c}_N^k \cdot e_i < 0$ , et pour  $a_i = Ae_i$  on pose

$$x^k(\epsilon) = (x_B^k(\epsilon), x_N^k(\epsilon)) \text{ avec } x_N^k(\epsilon) = \epsilon e_i, \quad x_B^k(\epsilon) = (B^k)^{-1}(b - \epsilon a_i).$$

Soit  $\epsilon^k \geq 0$  tel que  $x^k(\epsilon^k) \geq 0$  mais **il existe  $j$**  tel que  $x^k(\epsilon^k) \cdot e_j = 0$ . On pose

$$x^{k+1} = x^k(\epsilon^k),$$

et la base  $B^{k+1}$  est déduite de  $B^k$  en **remplaçant sa  $j$ -ème colonne par la colonne  $a_j$** .



## Remarques.

- Si toutes les solutions basiques  $x^k$  sont non dégénérées,  $x_B^k > 0$ , alors l'algorithme du simplexe converge en un nombre fini d'itérations.
- En théorie, on peut avoir besoin d'un nombre exponentiel d'itérations pour converger.
- En pratique, l'algorithme du simplexe converge en un nombre polynomial d'itérations.
- Il pourrait arriver (si  $x^k$  est dégénérée) que  $c \cdot x^{k+1} = c \cdot x^k$  et que l'algorithme ne converge pas (phénomène du cyclage). Mais ça n'arrive jamais en pratique...
- C'est un algorithme de type gradient ! Le vecteur des coûts réduits est un gradient projeté.



## Remarques pratiques.

- Le coût de calcul est lié à l'inversion de la base  $B^k$  (matrice  $m \times m$ ).
- Il existe d'excellents logiciels utilisant cet algorithme (avec beaucoup de petits "trucs"): ne pas essayer de le reprogrammer...
- Trouver une initialisation basique n'est pas toujours évident. Pour cela, on peut résoudre un autre programme linéaire

$$\min_{\substack{x \geq 0, y \geq 0 \\ Ax+y=b}} \sum_{i=1}^m y_i,$$

où on a préalablement changé le signe des contraintes pour que  $b \geq 0$ . On démarre de  $x^0 = 0$  et  $y^0 = b$  et on converge vers  $y = 0$  et  $x$  basique.



### 3 - Algorithme des points intérieurs

$$(LP) \quad \inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x.$$

On définit une **barrière logarithmique** pour  $x > 0$

$$\pi(x) = - \sum_{i=1}^n \log x_i.$$

On remplace (LP) par une version **pénalisée** avec  $\varepsilon > 0$

$$(LP_\varepsilon) \quad \min_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x > 0} \varepsilon \pi(x) + c \cdot x.$$

**L'algorithme de trajectoire centrale** minimise  $(LP_\varepsilon)$  par une méthode de Newton pour des valeurs  $\varepsilon \rightarrow 0$ .

- En pratique la contrainte  $x > 0$  n'est jamais active.
- Motivation théorique: complexité polynomiale (Khachian 1979).
- Algorithme pratique de Karmarkar (1984).



## 4 - Dualité en programmation linéaire

Commençons par quelques rappels de dualité.

**Définition.** Soit un Lagrangien  $\mathcal{L}(v, q)$  défini sur  $V \times P$ .

Pour  $v \in V$  on définit la fonction primale  $\mathcal{J}(v) = \sup_{q \in P} \mathcal{L}(v, q)$ .

Pour  $q \in P$  on définit la fonction duale  $\mathcal{G}(q) = \inf_{v \in V} \mathcal{L}(v, q)$ .

On appelle **problème primal**  $\inf_{v \in V} \mathcal{J}(v)$ .

On appelle **problème dual**  $\sup_{q \in P} \mathcal{G}(q)$ .

**Théorème (dualité forte).** Le couple  $(u, p)$  est un point-selle de  $\mathcal{L}$  sur  $V \times P$  **si et seulement si**

$$\mathcal{J}(u) = \min_{v \in V} \mathcal{J}(v) = \max_{q \in P} \mathcal{G}(q) = \mathcal{G}(p).$$



# Définition du problème dual en programmation linéaire

Soit le programme linéaire standard ou **problème primal**

$$(P) \quad \inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x$$

avec  $x, c \in \mathbb{R}^n$ ,  $b \in \mathbb{R}^m$  et  $A$  matrice  $m \times n$ . Pour  $p \in \mathbb{R}^m$  (multiplicateur de Lagrange), le Lagrangien est

$$L(x, p) = c \cdot x + p \cdot (b - Ax),$$

où on ne “dualise” que les contraintes d'égalité. On introduit la fonction duale

$$G(p) = \min_{x \geq 0} L(x, p) = \begin{cases} p \cdot b & \text{si } A^*p - c \leq 0 \\ -\infty & \text{sinon.} \end{cases}$$

Le **problème dual** est donc

$$(D) \quad \sup_{p \in \mathbb{R}^m \text{ tel que } A^*p - c \leq 0} p \cdot b$$





# Théorème de dualité en programmation linéaire

$$(P) \quad \inf_{x \in X_{ad}} c \cdot x, \quad X_{ad} = \{x \in \mathbb{R}^n \text{ tel que } Ax = b, x \geq 0\}$$

$$(D) \quad \sup_{p \in P_{ad}} p \cdot b, \quad P_{ad} = \{p \in \mathbb{R}^m \text{ tel que } A^*p - c \leq 0\}$$

**Théorème.** Si (P) ou (D) a une valeur finie, alors il existe un point selle  $(x^*, p^*)$  du Lagrangien et  $x^*$  est une solution optimale de (P) tandis que  $p^*$  est une solution optimale de (D).

**Remarque.** Le problème primal (P) a  $n$  inconnues et  $m$  contraintes, tandis que le problème dual (D) a  $m$  inconnues et  $n$  contraintes.

**Conséquence:** (P) ou (D) peut être plus facile. Résoudre les deux permet d'avoir une estimation d'erreur

$$p \cdot b \leq p^* \cdot b = c \cdot x^* \leq c \cdot x \quad \forall p \in P_{ad}, \forall x \in X_{ad}$$



# Théorème de dualité en programmation linéaire

**Preuve.** On suppose que  $X_{ad}$  et  $P_{ad}$  sont non vides (si ce n'est pas le cas, voir le polycopié). Soit  $x \in X_{ad}$  et  $p \in P_{ad}$ . Comme  $x \geq 0$  et  $A^*p \leq c$ , on a

$$c \cdot x \geq A^*p \cdot x = p \cdot Ax = p \cdot b,$$

puisque  $Ax = b$ . En particulier, cette inégalité implique que les valeurs optimales des deux problèmes, primal et dual, sont finies, donc qu'ils admettent des solutions optimales, notées  $x^*$  et  $p^*$ .

On applique alors le théorème de Kuhn et Tucker (les contraintes d'inégalité affines sont toujours qualifiées) et  $(x^*, p^*)$  est un point selle du Lagrangien, défini sur  $\mathbb{R}_+^n \times \mathbb{R}^m$  par

$$L(x, p) = c \cdot x + p \cdot (b - Ax).$$



## 5 - Initiation à la programmation en nombre entiers

Une ouverture vers la recherche opérationnelle.

Supposons que les données  $A, b$  soient des **entiers** (mais pas  $c$  !).

$$(LP) \quad \inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x$$

**Existe-t-il une solution optimale de (LP) telle que  $x \in \mathbb{Z}^n$  ?**

On propose un exemple (parmi d'autres) où la réponse est positive et la programmation linéaire est un outil utile:

**problème d'affectation** (cf. amphi 1).

Cet exemple repose sur la notion de matrices totalement unimodulaires.

Pour en savoir plus, voir le cours MAP557 de S. Gaubert (recherche opérationnelle).



# Matrices totalement unimodulaires

Une solution basique pour une base  $B$ , avec  $A = (B, N)$ , est

$$x_B = B^{-1}b, \quad x_N = 0.$$

Pour que  $x_B$  soit entier  $\forall b \in \mathbb{Z}^m$ , il faut que  $B^{-1}$  le soit aussi.

**Définition.** On dit qu'une matrice  $A \in \mathbb{Z}^{m \times n}$  est **totalement unimodulaire** si toute sous-matrice carrée extraite de  $A$  a un déterminant égal à  $\pm 1$  ou  $0$ .

**Proposition.** Toutes les solutions basiques de  $(LP)$  sont entières si  $A$  est totalement unimodulaire. En particulier,  $(LP)$  admet une solution entière.

**Preuve.** On utilise les formules de Cramer pour calculer  $x_B = B^{-1}b$  et on conclut car  $\det B = \pm 1$ .

Existe-t-il des matrices totalement unimodulaires ?



# Condition de Poincaré pour l'unimodularité

**Lemme (Poincaré).** Si  $A$  est une matrice à coefficients  $\pm 1$  ou  $0$ , avec **au plus** un coefficient  $1$  par colonne, et **au plus** un coefficient  $-1$  par colonne, alors  $A$  est **totalement unimodulaire**.

**Preuve.** L'hypothèse sur  $A$  est aussi vraie pour toutes ses sous-matrices. Donc il suffit de considérer le cas où la matrice  $A$  est carrée et de vérifier que  $\det A \in \{\pm 1, 0\}$ .

- S'il existe une colonne nulle de  $A$ , alors  $\det A = 0$ .
- S'il existe une colonne de  $A$  avec un seul coefficient non-nul, on développe son déterminant par rapport à cette colonne, et on conclut par récurrence sur la dimension de  $A$ .
- Si toutes les colonnes de  $A$  ont exactement un coefficient  $1$  et un coefficient  $-1$  (tous les autres sont  $0$ ), alors le vecteur  $(1, \dots, 1)$  appartient au noyau de la transposée de  $A$  et donc  $\det A = 0$ .



# Application: problème d'affectation

Soit une matrice  $N \times N$  de coefficients  $a_{ij} \geq 0$ . Si  $\mathcal{S}_N$  est l'ensemble des permutations de  $\{1, \dots, N\}$ , on maximise

$$(P) \quad \max_{\sigma \in \mathcal{S}_N} \sum_{i=1}^N a_{i\sigma(i)}.$$

Si on remplace la permutation  $\sigma$  par sa matrice  $(v_{ij})$ , (P) se réécrit

$$\max_{(v_{ij}) \in \{0,1\}^{N \times N}} \sum_{i=1}^N \sum_{j=1}^N a_{ij} v_{ij}$$

sous les contraintes

$$\sum_{j=1}^N v_{ij} = 1 \text{ pour } 1 \leq i \leq N, \quad \sum_{i=1}^N v_{ij} = 1 \text{ pour } 1 \leq j \leq N.$$



# Unimodularité du problème d'affectation

On ré-écrit le problème d'affectation ( $P$ ) sous la forme

$$\max_{(v_{ij}) \in \mathbb{Z}^{N \times N}} \sum_{i=1}^N \sum_{j=1}^N a_{ij} v_{ij}$$

sous les contraintes  $v_{ij} \geq 0$ , pour  $1 \leq i, j \leq N$ , et

$$(C) \quad \sum_{j=1}^N v_{ij} = 1 \text{ pour } 1 \leq i \leq N, \quad - \sum_{i=1}^M v_{ij} = -1 \text{ pour } 1 \leq j \leq N.$$

On peut écrire (C) comme  $Av = b$  avec  $v = (v_{ij})$  et  $A$  matrice de taille  $2N \times N^2$  où chaque colonne a exactement un coefficient  $+1$  et un  $-1$ , les autres étant 0.

Donc la matrice  $A$  est unimodulaire.



# Résolution pratique du problème d'affectation

On applique l'algorithme du simplexe au programme linéaire

$$\max_{v=(v_{ij}) \geq 0, Av=b} \sum_{i=1}^N \sum_{j=1}^N a_{ij} v_{ij}.$$

Comme la matrice  $A$  est unimodulaire, toutes les solutions basiques sont entières.

- 1 Une initialisation évidente du simplexe est  $v = \text{Id}$ .
- 2 Toutes les solutions successives du simplexe sont entières.
- 3 Toutes les solutions successives vérifient  $v_{ij} \in \{0, 1\}$  à cause des contraintes

$$\sum_{j=1}^N v_{ij} = 1, \quad \sum_{i=1}^M v_{ij} = 1.$$

