

# Programmation Semidéfinie et Optimisation Combinatoire

Frédéric Roupin

[roupin@lipn.univ-paris13.fr](mailto:roupin@lipn.univ-paris13.fr)

MPRO 2017-2018

# Plan du cours

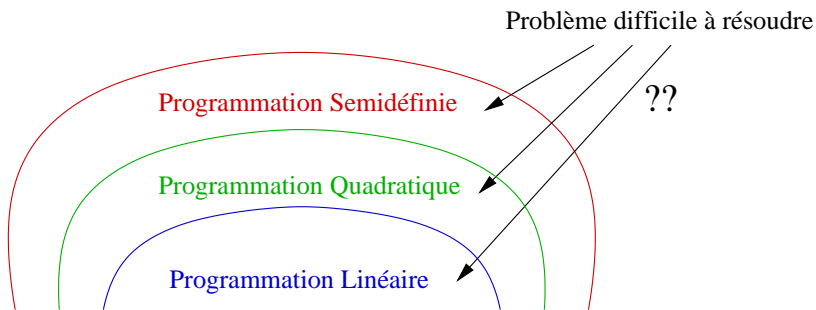
## 1. Introduction

## 2. Bases de la Programmation Semidéfinie

- Matrices positives : rappels
- Inégalités matricielles linéaires
- Programmes Semidéfinis
- Dualité en programmation Semidéfinie

# Problématique Générale

- **Objectif** : résoudre des problèmes combinatoires ou continus non-convexes
- Problèmes généralement NP-difficiles
- **Démarche** : établir des **relaxations convexes** pour obtenir des **bornes** (inférieures ou supérieures)



- algorithmes **approchés**
- méthodes de **séparation/évaluation** (Branch&Bound)
- méthodes de **Branch&Cut**


## Relaxation d'un problème d'optimisation difficile

Un problème  $P$  : on cherche à optimiser  $f(x)$  pour  $x$  dans une région  $X$  **non convexe** (souvent définie par un ensemble de contraintes)

**Objectif.** Obtenir une **borne de la valeur optimale**

**Méthode.** **Relaxation convexe** du problème. Trouver  $X'$  convexe tel que :

- $X \subset X'$ .
- Optimiser  $f(x)$  pour  $x \in X'$  est "facile".
- Le saut  $\sigma = |val_{opt}(P) - val_{opt}(P')|$  dû à la relaxation est petit.
- Cas "idéal" : enveloppe convexe de  $X$ .
- Méthodes réalistes : programmation linéaire, programmation semidéfinie (cas non-linéaire).



# Mixed Integer Non-Linear Programming

## Modèle Mathématique

- Mixed Integer Non-Linear Problems

$$\begin{array}{ll} \min & g_0(x) \\ \text{sous contraintes :} & g_k(x) \leq 0 \quad k = 1, \dots, m \\ & l \leq x \leq u \\ & x_j \in \mathbb{Z} \quad i = 1, \dots, p \end{array}$$

- Certaines fonctions  $g_k(x)$  sont **non-linéaires**.
- Sont combinées ici les difficultés de deux sous-classes de problèmes : **contraintes d'intégrité** et **non-convexité**.
- Très souvent, les variables entières sont utilisées :
  - ▶ pour faire un choix entre plusieurs options : **variables de décision**
  - ▶ Pour activer/désactiver des variables continues ou des contraintes.

# Mixed Integer Non-Linear Programming

## Modèle mathématique

- Mixed Integer Non-Linear Problems

$$\begin{array}{ll} \min & g_0(x) \\ \text{sous contraintes :} & g_k(x) \leq 0 \quad k = 1, \dots, m \\ & l \leq x \leq u \\ & x_j \in \mathbb{Z} \quad i = 1, \dots, p \end{array}$$

- Peu de solvers peuvent attaquer cette classe générale de problèmes.  
**Méthodes:** (spatial)Branch-and-Bound (relaxations convexes), Cutting Planes, décomposition de Bender généralisée,...
- Le choix du modèle est déterminant** pour la qualité des relaxations sous-jacentes. L'approche "black box" peut être catastrophique (preprocessing hasardeux, instabilité numérique,...).
- Convexifications : LP, CQP, SDP.** En particulier, les fonctions ou contraintes non-convexes et/ou non quadratiques sont souvent approximées.

# Cas particuliers Quadratiques

## Mixed Integer Quadratically Constrained Quadratic Programming

$$(MIQCQP) \quad \begin{array}{ll} \min & x^T Q_0 x + c_0^T x \\ \text{s.c.} & x^T Q_i x + c_i^T x \leq a_i \quad i \in \{1, \dots, m\} \\ & l \leq x \leq u \\ & x_j \in \mathbb{Z} \quad j = 1, \dots, p \end{array}$$

- Toutes les fonctions  $g_k(x)$  sont quadratiques (ou linéaires).
- Peut malgré tout modéliser beaucoup de problèmes combinatoires !
- Peut apparaître comme un sous-problème lors de la résolution d'un MINLP plus général.

## Mixed Integer Quadratic Programming

$$(MIQP) \quad \begin{array}{ll} \min & x^T Q x + c^T x \\ \text{s.c.} & Ax = b \\ & l \leq x \leq u \\ & x_j \in \mathbb{Z} \quad j = 1, \dots, p \end{array}$$

# Généralités sur la programmation semidéfinie

- Utilisation assez récente en optimisation combinatoire
- Cas particulier de programmation convexe non-linéaire (fonction et contraintes convexes)
- Généralisation de la programmation linéaire (tout PL est un SDP particulier).
- *Avantage* : relaxation plus “fine” que la PL, bornes de très bonne qualité
- *Inconvénient* : résolution numérique coûteuse
  - ▶ => généralement réservée aux problèmes difficiles (lorsque l’approche par PL échoue)

Slides du cours/Polycopié :

<http://www-lipn.univ-paris13.fr/~roupin/>



# Matrices (Semidéfinies) Positives

$S_n$  : espace des matrices réelles symétriques  $n \times n$

Produit scalaire dans  $S_n$  :

$$(A, B) \in S_n^2 \quad A \bullet B = \sum_{i=1}^n \sum_{j=1}^n A_{ij} B_{ij}$$

## Definition

$A \in S_n$  est positive,  $A \succcurlyeq 0$ , si et seulement si pour tout  $x \in \mathbb{R}^n$

$$x^T A x = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j = A \bullet x x^T \geq 0$$

$$x x^T = \begin{bmatrix} x_1^2 & \cdots & x_1 x_i & \cdots & x_1 x_n \\ \vdots & \ddots & & & \vdots \\ x_i x_1 & & x_i^2 & & x_i x_n \\ \vdots & & & \ddots & \vdots \\ x_n x_1 & \cdots & x_n x_i & \cdots & x_n^2 \end{bmatrix}$$

**Exemple.**  $x_1^2 + 2x_2^2 - x_1 x_2 + x_1 = \begin{bmatrix} 1 & -\frac{1}{2} \\ -\frac{1}{2} & 2 \end{bmatrix} \bullet x x^T + \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

# Matrices (Semidéfinies) Positives

## Proposition

$A \in S_n$  est positive,  $A \succcurlyeq 0$  si et seulement si  $A = M^T \begin{bmatrix} \lambda_1 & \dots & 0 \\ 0 & \ddots & 0 \\ 0 & \dots & \lambda_n \end{bmatrix} M$

avec  $\lambda \geq 0$  et  $M^T M = I$

## Definition

**Mineur symétrique d'une matrice** : déterminant d'une sous-matrice obtenue en choisissant un sous-ensemble de lignes et de colonnes de mêmes indices

## Proposition

Une matrice est (semidéfinie) positive si et seulement si tous ses mineurs symétriques sont positifs ou nuls

# Matrices (définies) positives : Définitions équivalentes

## Matrices définies positives :

$A \succ 0$
$\forall z \neq 0 \in \mathbb{R}^n \quad z^T A z > 0$
Les valeurs propres de $A$ sont $> 0$
Les mineurs <b>principaux</b> de $A$ sont $> 0$

## Matrices positives (semidéfinies positives)

$A \succcurlyeq 0$
$\forall z \in \mathbb{R}^n \quad z^T A z \geq 0$
Les valeurs propres de $A$ sont $\geq 0$
Les mineurs <b>symétriques</b> de $A$ sont $\geq 0$

$\succcurlyeq$  définit un **ordre partiel** :  $A \succcurlyeq B \Leftrightarrow A - B \succcurlyeq 0$ .

## Definition

### **Mineur symétrique d'une matrice :**

déterminant d'une sous-matrice obtenue en choisissant un sous-ensemble de lignes et de colonnes de mêmes indices

## Proposition

*Une matrice est (semidéfinie) positive si et seulement si tous ses mineurs symétriques sont positifs ou nuls*

*Exemple :*  $A = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 6 & 4 \\ 1 & 4 & 3 \end{bmatrix}$

- mineurs symétriques  $1 \times 1$  :  $1 \geq 0, 6 \geq 0, 3 \geq 0$
- mineurs symétriques  $2 \times 2$  :  $6 - 4 \geq 0, 18 - 16 \geq 0, 3 - 1 \geq 0$
- mineur symétrique  $3 \times 3$  :  $\det(A) = 0 \geq 0$

# Décomposition de Cholesky

## Théorème


Une matrice  $A$  symétrique est définie positive si et seulement si elle est factorisable sous la forme  $A = VV^T$  où  $V$  est une matrice triangulaire inférieure à diagonale positive. Cette factorisation est unique.

- $A$  est la matrice de Gram de  $n$  vecteurs  $v_1, \dots, v_n$  de  $\mathbb{R}^n$  :  
 $\forall (i, j) \ a_{ij} = v_i^T v_j$ . i.e.  $A = VV^T$ . En particulier les éléments diagonaux de  $A$  sont les normes au carré des vecteurs lignes de  $V$ .
- Décomposition de Cholesky incomplète : si  $A$  n'est pas définie et de rang  $r$ , elle est également factorisable en  $VV^T$  avec  $\text{rang}(V) = r$ .  
Mais il n'y a plus unicité :

$$\begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 2 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 2 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 5 & 2 & 0 \\ 0 & 2 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$
$$\begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & \sqrt{5} & 0 & 0 \\ 0 & \frac{2}{\sqrt{5}} & \frac{1}{\sqrt{5}} & 0 \\ 0 & 0 & \frac{0}{\sqrt{5}} & 1 \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & \sqrt{5} & \frac{2}{\sqrt{5}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{5}} & 0 \\ 0 & 0 & \frac{0}{\sqrt{5}} & 1 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 5 & 2 & 0 \\ 0 & 2 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

## Cas particulier important pour la modélisation en SDP

$\forall i \in \{1, \dots, n\}, A_{ii} = 1 \Leftrightarrow$  vecteurs  $v_1, \dots, v_n \in S^n$ , sphère unité.



**Conséquence** : se donner une matrice positive  $n \times n$  dont les éléments diagonaux valent tous 1 équivaut à se donner un champ de vecteurs de la sphère unité de  $\mathbb{R}^n \rightarrow$  **Changement de variables**

# Inégalités matricielles linéaires

## Definition

On appelle **inégalité matricielle linéaire** toute expression de la forme  $\sum_{i=1}^m x_i A_i \succcurlyeq A_0$ , où  $A_i \in S_n$  ( $i = 0, \dots, m$ ) et les  $x_i$  sont des variables réelles

**Exemple 1.** Soit un réel  $t$  tel que  $\begin{bmatrix} 1 & t & 1 \\ t & 2 & 1 \\ 1 & 1 & 4-t \end{bmatrix} \succcurlyeq 0$

ce qui est équivalent à l'*infinité* d'inégalités linéaires simples :

$$\forall z \in R^n, z^T X z \geq 0. \text{ avec } X = \begin{bmatrix} 1 & t & 1 \\ t & 2 & 1 \\ 1 & 1 & 4-t \end{bmatrix}$$


$$\text{ex. } \begin{bmatrix} 1 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & t & 1 \\ t & 2 & 1 \\ 1 & 1 & 4-t \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix} = 7 - t \geq 0$$

$$\begin{bmatrix} 1 & t & 1 \\ t & 2 & 1 \\ 1 & 1 & 4-t \end{bmatrix} \succcurlyeq 0$$

Cherchons  $t$  vérifiant l'inégalité matricielle, i.e.  $t$  vérifiant :

$$4 - t \geq 0 ; \quad 2 - t^2 \geq 0 ; \quad 3 - t \geq 0 ;$$


$$7 - 2t \geq 0 ; \quad t^3 - 4t^2 + 5 \geq 0.$$



$\Rightarrow$  deux inégalités linéaires simples :  $-1 \leq t \leq 1,381966$



**Exemple 2.** Soit  $x$  et  $t$  réels vérifiant  $\begin{bmatrix} x & 1 \\ 1 & t \end{bmatrix} \succcurlyeq 0$   
 $\iff x \geq 0, t \geq 0, xt \geq 1$  (mineurs symétriques).



La région du plan obtenue est convexe mais n'est pas un polytope.

## Inégalités matricielles linéaires (2)

- Soient  $A_0, A_1, \dots, A_m$  dans  $S_n$ , espace des matrices réelles symétriques  $n \times n$
- Pour  $x \in \mathbb{R}^m$  on pose  $F(x) = \sum_{i=1}^m x_i A_i - A_0$

$F(x)$  est une matrice appartenant à l'espace affine défini par le repère :

- $-A_0$  : origine
- $A_1, \dots, A_m$  base
- $x$  : coordonnées de  $F(x)$  dans ce repère

## Inégalités matricielles linéaires (3)

Étudions  $S = \{x \in \mathbb{R}^m : F(x) = \sum_{i=1}^m x_i A_i - A_0 \succcurlyeq 0\}$

$S$  est défini par une **inégalité matricielle linéaire**

- $F(x)$  est dans l'**intersection** d'un espace affine et du cône des matrices (semidéfinies) positives

- La région recherchée est **convexe** car  $F$  est linéaire :

$$F(\lambda x + (1 - \lambda)y) = \lambda F(x) + (1 - \lambda)F(y) \succcurlyeq 0$$

$$\forall \lambda \in [0, 1], x \in S, y \in S$$

- mais n'est généralement pas un polytope pour  $m \geq 2$ :

$$x \text{ et } y \text{ réels vérifiant } \begin{bmatrix} x & 1 \\ 1 & y \end{bmatrix} \succcurlyeq 0$$

$$\iff x \geq 0, y \geq 0, xy \geq 1 \text{ (mineurs symétriques)}$$



# Propriétés topologiques

$$S = \{x \in \mathbb{R}^m : \sum_{i=1}^m A_i x_i - A_0 \succ 0\}$$

## Théorème

o

$$S = \{x \mid F(x) \succ 0\} \quad \text{et} \quad \partial S = \{x \mid F(x) \succcurlyeq 0 \text{ et } \det F(x) = 0\}$$




## Nature de la frontière

$\det F(x) = 0 \Leftrightarrow x$  annule un certain nombre de polynômes. En effet certains mineurs de  $F(x)$  sont nuls (le nombre dépend du rang de  $F(x)$ ).

→ On obtient des surfaces algébriques. En PL seulement des hyperplans !

**Exemple.**  $F(x) = \begin{bmatrix} x_1 & 1 & 0 \\ 1 & x_2 + 1 & 0 \\ 0 & 0 & x_2 \end{bmatrix} \succcurlyeq 0$

On cherche  $x$  tel que  $\det F(x) = 0$ .



Frontière:  $\{x : x_1(x_2 + 1) - 1 = 0, 0 < x_1 < 1\} \cup \{x : x_2 = 0, x_1 \geq 1\}$

# Programmes Semidéfinis

## Definition

Un programme semidéfini est la minimisation d'une forme linéaire de  $\mathbb{R}^m$  soumise à une inégalité matricielle linéaire

$$(SDP) \begin{cases} \min & c^T x \\ \text{s.c.} & F(x) = \sum_{i=1}^m x_i A_i - A_0 \succcurlyeq 0 \end{cases}$$

## Proposition

La programmation linéaire est un cas particulier de la programmation semidéfinie:

$$(PL) \begin{cases} \min & c^T x \\ \text{s.c.} & F(x) = \mathbf{diag}(Ax - b) \succcurlyeq 0 \Leftrightarrow Ax - b \geq 0 \end{cases}$$

$A_i^T x - b_i$  est valeur propre (positive) de la matrice diagonale  $F(x)$

## Formulation d'un PL en PSD

$$(PL) \begin{cases} \text{Minimiser} & c^T x \\ \text{Sous contrainte} & F(x) = \mathbf{diag}(Ax - b) \succcurlyeq 0 \end{cases}$$

**Exemple.**

$$(P) \begin{cases} \text{Minimiser} & x_1 + 3x_2 \\ \text{s.c. :} & 2x_1 - x_2 \geq 1 \\ & 5x_1 + 7x_2 \geq -6 \end{cases}$$

$$\Leftrightarrow (SDP) \begin{cases} \text{Minimiser} & x_1 + 3x_2 \\ \text{s.c. :} & \begin{bmatrix} 2x_1 - x_2 - 1 & 0 \\ 0 & 5x_1 + 7x_2 + 6 \end{bmatrix} \succcurlyeq 0 \end{cases}$$

# Optimisation Semidéfinie vs Optimisation Linéaire


## Produit scalaire et positivité

$$\text{PL : } c^T x = \sum_i c_i x_i$$


$$\text{SDP : } C \bullet X = \sum_{ij} C_{ij} X_{ij}$$

$$\text{Cône } \mathbb{R}^{n+} = \{x : x^T y \geq 0 \forall y \in \mathbb{R}^{n+}\}$$

$$\text{Cône } \mathcal{S}_+^n = \{X : X \bullet Y \geq 0 \forall Y \in \mathcal{S}_+^n\}$$



$$S_n^+ = \{X \in S_n : X \bullet zz^T \geq 0 \forall z \in \mathbb{R}^n\}$$



$\mathbb{R}^{n+}$



# Optimisation Semidéfinie vs Optimisation Linéaire


## Produit scalaire et positivité

$$\text{PL : } c^T x = \sum_i c_i x_i$$

$$\text{SDP : } C \bullet X = \sum_{ij} C_{ij} X_{ij}$$

$$\text{Cône } \mathbb{R}^{n+} = \{x : x^T y \geq 0 \forall y \in \mathbb{R}^{n+}\}$$

$$\text{Cône } \mathcal{S}_+^n = \{X : X \bullet Y \geq 0 \forall Y \in \mathcal{S}_+^n\}$$



$$\mathcal{S}_n^+ = \{X \in \mathcal{S}_n : X \bullet zz^T \geq 0 \forall z \in \mathbb{R}^n\} \Leftrightarrow X \succcurlyeq 0$$

$$(\text{SDP}) \begin{cases} \min & C \bullet X & = \sum_{i=1}^n \sum_{j=1}^n C_{ij} X_{ij} \\ \text{s.c.} & A_i \bullet X = b_i & \forall i \in \{1, \dots, m\} \\ & X \succcurlyeq 0 \end{cases}$$

# Outil fondamental pour la modélisation : les compléments de Schur

## Théorème

Si  $A$  matrice  $p \times p$  définie positive,  $C \in S_n$ , et  $B$  matrice  $p \times n$ , alors

$\begin{bmatrix} A & B \\ B^T & C \end{bmatrix} \succcurlyeq 0$  est équivalent à  $C - B^T A^{-1} B \succcurlyeq 0$ .

$$\begin{bmatrix} A & B \\ B^T & C \end{bmatrix} = \begin{bmatrix} I & 0 \\ B^T A^{-1} & I \end{bmatrix} \begin{bmatrix} A & 0 \\ 0 & C - B^T A^{-1} B \end{bmatrix} \begin{bmatrix} I & A^{-1} B \\ 0 & I \end{bmatrix}$$

## Cas particuliers importants

- $A = I_p$ . On a  $\begin{bmatrix} I_p & B \\ B^T & C \end{bmatrix} \succcurlyeq 0 \Leftrightarrow C - B^T B \succcurlyeq 0$
- $p = 1$ ,  $C = X$ ,  $B = x^T$ . Soit  $(X, x) \in S_n \times \mathbb{R}^n$ , on a

$$X - xx^T \succcurlyeq 0 \Leftrightarrow \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succcurlyeq 0$$

## Exemple de PSD non linéaire non formulable en PL

$$(P) \begin{cases} \text{Minimiser} & \frac{(c^T x)^2}{d^T x} \\ \text{s.c.} & Ax + b \geq 0 \end{cases}$$

Hypothèse:  $Ax + b \geq 0$  implique  $d^T x > 0$ .

$$\begin{cases} \text{Minimiser} & t \\ \text{s.c.} & Ax + b \geq 0 \\ & \frac{(c^T x)^2}{d^T x} \leq t \end{cases}$$

$t$  : complément de Schur

$$\begin{cases} \text{Minimiser} & t \\ \text{s.c.} & \begin{bmatrix} \text{diag}(Ax + b) & 0 & 0 \\ 0 & t & c^T x \\ 0 & c^T x & d^T x \end{bmatrix} \succcurlyeq 0 \end{cases}$$

## Exemple d'application : Résolution approchée d'un système linéaire

Soit  $A \in \mathbb{R}^{p \times n}$ , et  $Ax = b$  n'admettant pas de solution. On décide de minimiser :

$$\max_{i \in \{1, \dots, p\}} \left| A_i^T x - b_i \right|$$

avec  $A_i$  : ième ligne ( $i \in \{1, \dots, p\}$ ) de  $A$

- 1 Modéliser ce problème comme un programme linéaire.
- 2 Dans certaines applications les quantités  $b_i$  sont exprimées à l'aide d'une échelle logarithmique (car elles représentent par exemple une puissance ou une intensité). On souhaite alors minimiser

$$\max_{i \in \{1, \dots, p\}} \left| \log \left( A_i^T x \right) - \log (b_i) \right|$$

modéliser ce nouveau problème comme un programme semidéfini.

# Programmation Quadratique Convexe

## Proposition

La programmation Quadratique Convexe est un cas particulier de la Programmation Semidéfinie

$\forall i \in \{0, \dots, m\}$   $f_i(x) = x^T A_i^T A_i x + c_i^T x + d_i$  est **convexe**

$$(Q) \begin{cases} \min & f_0(x) \\ \text{s.c.} & f_i(x) \leq 0 \quad i = 1, \dots, m \end{cases}$$

Schur :  $f_i(x) \leq 0 \Leftrightarrow \begin{bmatrix} I_n & A_i x \\ x^T A_i^T & -c_i^T x - d_i \end{bmatrix} \succcurlyeq 0$

$$(Q) \Leftrightarrow \begin{cases} \min & t \\ \text{s.c.} & \begin{bmatrix} I_n & A_0 x \\ x^T A_0^T & -c_0^T x - d_0 + t \end{bmatrix} \succcurlyeq 0 & f_0(x) - t \leq 0 \\ & \begin{bmatrix} I_n & A_i x \\ x^T A_i^T & -c_i^T x - d_i \end{bmatrix} \succcurlyeq 0 \quad \forall i \neq 0 \end{cases}$$

## Programmation Quadratique Convexe (2)

$$(Q) \begin{cases} \min & x^T A_0^T A_0 x + c_0^T x + d_0 (\leq t) \\ \text{s.c.} & x^T A_i^T A_i x + c_i^T x + d_i \leq 0 \quad i = 1, \dots, m \end{cases}$$

Utilisation d'une **unique** inégalité matricielle linéaire:

$$(Q) \Leftrightarrow \begin{cases} \min & t \\ \text{s.c.} & \begin{bmatrix} d_0 - t & \frac{1}{2}c_0^T \\ \frac{1}{2}c_0 & A_0^T A_0 \end{bmatrix} \bullet \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \leq 0 \\ & \begin{bmatrix} d_i & \frac{1}{2}c_i^T \\ \frac{1}{2}c_i & A_i^T A_i \end{bmatrix} \bullet \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \leq 0 \\ & \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succcurlyeq 0 \end{cases}$$

$$\underbrace{A_i^T A_i \bullet (X - xx^T)}_{\geq 0} + x^T A_i^T A_i x + c_i^T x + d_i \leq 0$$

## Utilisation de la même idée en PL

Montrons que :

$$(PL) \left\{ \begin{array}{ll} \min & x_1 + 4x_2 \\ \text{Sous les contraintes} & x_1 - x_2 + x_3 = 2 \\ & 3x_1 - 5x_3 = 6 \\ & x_1 \geq 0, x_2 \geq 0, x_3 \geq 0 \end{array} \right.$$

est équivalent à

$$(SDP) \left\{ \begin{array}{ll} \text{Minimiser} & x_1 + 4x_2 \\ \text{Sous les contraintes} & (e_1 e_1^T + e_2 e_2^T) \bullet X - (4e_1 + 12e_2)^T x + 40 = 0 \\ & \begin{bmatrix} \text{diag}(x) & 0 & 0 \\ 0 & 1 & x^T \\ 0 & x & X \end{bmatrix} \succcurlyeq 0 \end{array} \right.$$

$$\text{où } e_1 = \begin{pmatrix} 1 \\ -1 \\ 1 \end{pmatrix}, e_2 = \begin{pmatrix} 3 \\ 0 \\ -5 \end{pmatrix}$$

# Dualité

- Le programme dual de (SDP) est

$$\sup_{Z \succcurlyeq 0} \inf_{x \in \mathbb{R}^m} L(x, Z)$$

avec  $L(x, Z) = c^T x + Z \bullet (A_0 - \sum_{i=1}^m x_i A_i)$

- ▶ Le **multiplieur de Lagrange**  $Z$  associé à l'**inégalité** matricielle linéaire  $F(x) \succcurlyeq 0$  est une matrice **positive**
- ▶ A comparer avec le lagrangien d'une inégalité linéaire  $a^T x - b \geq 0$  :  
 $L(x, \lambda) = c^T x + \lambda^T (b - a^T x)$  avec  $\lambda \geq 0$
- Fonction duale :
  - ▶ si  $A_i \bullet Z = c_i \forall i \in \{1, \dots, m\}$  alors  $\inf_{x \in \mathbb{R}^m} L(x, Z) = A_0 \bullet Z$
  - ▶ Sinon : les termes en  $x_i$  ne sont pas tous annulés et  $\inf_{x \in \mathbb{R}^m} L(x, Z) = -\infty$

## Proposition

Le programme dual de (SDP) est un programme semidéfini :

$$(DSDP) \begin{cases} \sup & A_0 \bullet Z \\ \text{s.c.} & A_i \bullet Z = c_i \quad i \in \{1, \dots, m\} \\ & Z \succcurlyeq 0 \end{cases}$$



# Formes Duale et Primale

(DSDP) est un programme semidéfini

- Dans le **primal** : variable  $x \in \mathfrak{R}^m$
- Dans le **dual** : variable  $Z \in S_n$
- $F(x)$  et  $Z$  appartiennent à l'intersection d'un espace affine (pas le même !) et du cône des matrices positives
- Soit un **repère**  $(-B_0, B_1, \dots, B_p)$  (origine + base) de  $\mathfrak{N}_0 = \{Z; Z \in S_n, A_i \bullet Z = c_i, i = 1, \dots, p\}$
- $Z = F(y) = -B_0 + \sum_{i=1}^p y_i B_i$

Réécriture de (DSDP) sous forme primale

$$(DSDP) \begin{cases} \sup & A_0 \bullet Z = A_0 \bullet (-B_0 + \sum_{i=1}^p y_i B_i) \\ \text{s.c. :} & A_i \bullet Z = c_i \quad i = 1, \dots, m \\ & \Leftrightarrow Z = F(y) = -B_0 + \sum_{i=1}^p y_i B_i \succeq 0 \end{cases}$$

# Théorèmes de Dualité

## Lemme

Soit  $A$  et  $B$  dans  $S_n$ . Si  $A \succcurlyeq 0$  et  $B \succcurlyeq 0$  alors  $A \bullet B \geq 0$  et l'égalité est atteinte si et seulement si  $AB = 0$

## Dualité Faible

Le saut de dualité entre (DSP) et (SDP)

vaut:  $c^T x - A_0 \bullet Z = \sum_{i=1}^m (A_i \bullet Z) x_i - A_0 \bullet Z = F(x) \bullet Z \geq 0$

**Dualité Forte** (qualification de type "Slater")

- Le problème primal est strictement réalisable (il existe des points intérieurs :  $\exists x / F(x) \succ 0$ ).
- Le problème dual est strictement réalisable ( $\exists Z / Z = Z^T \succ 0, A_i \bullet Z = c_i, i = 1, \dots, m$ )
- Si les deux conditions sont remplies alors il n'y a **pas de saut de dualité** et il existe des solutions optimales pour le primal et le dual

## Exemple d'application des théorèmes de dualité

$\text{Inf} \left\{ x : \begin{bmatrix} x & 1 \\ 1 & t \end{bmatrix} \succcurlyeq 0 \right\} = 0$  n'est pas atteint.

Dual de :  $\text{Inf } x \text{ s.c. : } \begin{bmatrix} x & 1 \\ 1 & t \end{bmatrix} \succcurlyeq 0 ?$

$\text{Max } -2Z_{12} \text{ s.c. : } Z_{11} = 1; Z_{22} = 0; Z \succcurlyeq 0$

Région admissible du programme dual :

$$Z = \begin{bmatrix} 1 & Z_{12} \\ Z_{12} & 0 \end{bmatrix} \succcurlyeq 0 \Rightarrow -Z_{12}^2 \geq 0.$$

$\Rightarrow$  Un seul point admissible :  $\begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$

Application du Théorème :

- Le primal est d'intérieur non vide : pas de saut de dualité.
- Région admissible du dual d'intérieur vide : pas forcément de solution (c'est le cas du primal ici).

# Conditions des écarts complémentaires en SDP

## Proposition

Supposons que le saut de dualité est nul ( $F(x) \bullet Z = 0$ ).  $x$  et  $Z$  sont respectivement optimaux pour (SDP) et (DSDP) si et seulement si:

$$F(x) \succeq 0$$

$$Z \succeq 0, A_i \bullet Z = c_i, i = 1, \dots, m$$

$$ZF(x) = 0 \Leftrightarrow F(x) \bullet Z = 0$$

Généralisation du cas linéaire :

- En programmation linéaire  $F(x) = \mathbf{diag}(Ax - b)$  et  $Z$  sont **diagonales**
- $ZF(x)$  s'écrit  $Z_{ii}\mathbf{diag}(Ax - b)_{ii} = Z_{ii} (A_i^T x - b_i) = 0 \forall i$

# Optimisation Semidéfinie vs Optimisation Linéaire

Les Programmes duaux respectifs appartiennent à la même classe de problèmes

(PL)

$$\begin{array}{ll} \text{minimiser} & c^T x \\ \text{sous contraintes} & a_i^T x = b_i, \quad i = 1, \dots, m \\ & x \geq 0 : \mathbb{R}^{n+} \end{array}$$

(SDP)

$$\begin{array}{ll} \text{minimiser} & C \bullet X \\ \text{sous contraintes} & A_i \bullet X = b_i, \quad i = 1, \dots, m \\ & X \succeq 0 : \mathcal{S}_+^n \end{array}$$

## Produit scalaire et positivité

$$\text{PL : } c^T x = \sum_i c_i x_i \quad \text{Cône } \mathbb{R}^{n+} = \{x : x^T y \geq 0 \forall y \in \mathbb{R}^{n+}\}$$

$$\text{SDP : } C \bullet X = \sum_{ij} C_{ij} X_{ij} \quad \text{Cône } \mathcal{S}_+^n = \{X : X \bullet Y \geq 0 \forall Y \in \mathcal{S}_+^n\}$$

→ Chacun de ces cônes est son propre cône dual : le dual d'un PL est un PL, et le dual d'un SDP est un SDP.

## Exemple d'application

$$(SDP) \begin{cases} \min_{z \in \mathbb{R}} & z \\ \text{s.c.} & \begin{bmatrix} 3z & -z - 1 \\ -z - 1 & 3z \end{bmatrix} \succeq 0 \end{cases}$$

- 1 Résoudre (*SDP*), i.e. donner sa valeur optimale ainsi que l'ensemble des solutions optimales.
- 2 Ecrire (*DSDP*), le programme dual de (*SDP*).
- 3 Montrer qu'il n'y a pas de saut de dualité entre (*DSDP*) et (*SDP*), et résoudre (*DSDP*) en utilisant les conditions des écarts complémentaires.

## Exemple d'application (suite)

$$(SDP) \begin{cases} \min_{z \in \mathbb{R}} & z \\ \text{s.c.} & \begin{bmatrix} 3z & -z-1 \\ -z-1 & 3z \end{bmatrix} \succeq 0 \end{cases}$$

- 1 Soit le programme quadratique :

$$(P) \begin{cases} \max & 2x_1x_2 \\ \text{s.c.} & 3x_1^2 + 3x_2^2 - 2x_1x_2 = 1 \\ & (x_1, x_2) \in \mathbb{R}^2 \end{cases}$$

Etablir que la valeur optimale de  $(DSDP)$  est supérieure ou égale à celle de  $(P)$ , en montrant que  $(DSDP)$  est une relaxation de  $(P)$ .

- 2 Donner le rang de la solution optimale de  $(DSDP)$  trouvée à la question 3. En déduire une solution optimale de  $(P)$ .