

# Programmation Quadratique en variables 0-1

Frédéric Roupin

roupin@ensiie.fr

Master M2 MMMEF

# Plan du cours

## 1. Introduction

# Plan du cours

1. Introduction
2. Linéarisations

# Plan du cours

1. Introduction
2. Linéarisations
3. Approches Lagrangiennes

# Plan du cours

1. Introduction
2. Linéarisations
3. Approches Lagrangiennes
4. Approche par Programmation Semidéfinie

# Plan du cours

1. Introduction
  - a. Modèle Général étudié
  - b. Modéliser à l'aide de variables 0-1
  - c. Cas Quadratique 0-1 sans contrainte
  - d. Exemples concrets de formulations
2. Linéarisations
3. Approches Lagrangiennes
4. Approche par Programmation Semidéfinie

# Plan du cours

1. Introduction
  - a. Modèle Général étudié
  - b. Modéliser à l'aide de variables 0-1
  - c. Cas Quadratique 0-1 sans contrainte
  - d. Exemples concrets de formulations
2. Linéarisations
3. Approches Lagrangiennes
4. Approche par Programmation Semidéfinie

## I.a. Modèle Général étudié

Définition d'un programme Quadratique en variables 0-1

$$(Q) \left\{ \begin{array}{l} \min \quad x^T Q x + b^T x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j + \sum_{i=1}^n b_i x_i \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ \quad \quad Ax = (\text{ou } \leq) b \\ \quad \quad x \in \{0, 1\}^n \end{array} \right.$$



## I.a. Modèle Général étudié

Définition d'un programme Quadratique en variables 0-1

$$(Q) \begin{cases} \min & x^T Q x + b^T x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j + \sum_{i=1}^n b_i x_i \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

- $x$  : vecteur des variables de **décision**

## I.a. Modèle Général étudié

Définition d'un programme Quadratique en variables 0-1

$$(Q) \begin{cases} \min & x^T Q x + b^T x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j + \sum_{i=1}^n b_i x_i \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

- $x$  : vecteur des variables de **décision**
- $x \in \{0, 1\}^n \Leftrightarrow x_i^2 = x_i \quad \forall i \in \{1, \dots, n\}$   
 $\Rightarrow$  problème **continu** !

## I.a. Modèle Général étudié

Définition d'un programme Quadratique en variables 0-1

$$(Q) \begin{cases} \min & x^T Q x + b^T x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j + \sum_{i=1}^n b_i x_i \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

- $x$  : vecteur des variables de **décision**
- $x \in \{0, 1\}^n \Leftrightarrow x_i^2 = x_i \quad \forall i \in \{1, \dots, n\}$   
 $\Rightarrow$  problème **continu** !
- Cas particulier : programmation linéaire en 0-1

# Problématique Générale

# Problématique Générale

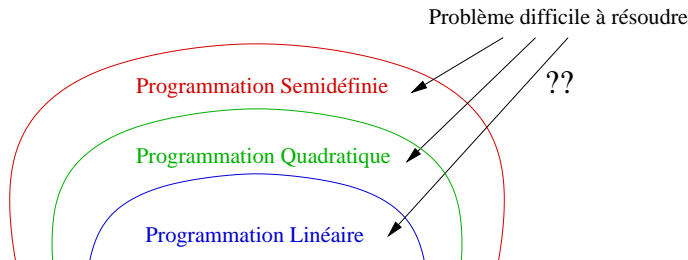
- Très large spectre d'application

# Problématique Générale

- Très large spectre d'application
- Mais problèmes généralement NP-difficiles


# Problématique Générale

- Très large spectre d'application
- Mais problèmes généralement NP-difficiles
- Principe général : établir des **relaxations convexes** pour les cas difficiles pour obtenir des **bornes** (inférieures ou supérieures)



# Problématique Générale

- Très large spectre d'application
- Mais problèmes généralement NP-difficiles
- Principe général : établir des **relaxations convexes** pour les cas difficiles pour obtenir des **bornes** (inférieures ou supérieures)

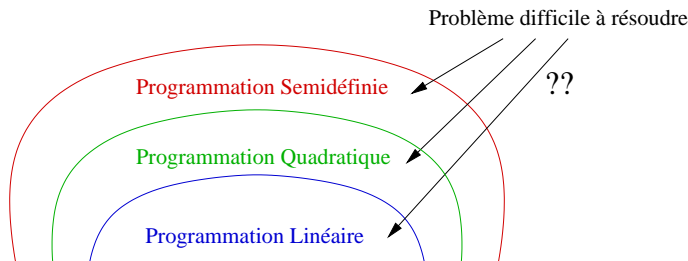


- méthodes de **séparation/évaluation** (Branch&Bound)



# Problématique Générale

- Très large spectre d'application
- Mais problèmes généralement NP-difficiles
- Principe général : établir des **relaxations convexes** pour les cas difficiles pour obtenir des **bornes** (inférieures ou supérieures)



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

# Plan du cours

1. Introduction
  - a. Modèle Général étudié
  - b. Modéliser à l'aide de variables 0-1
  - c. Cas Quadratique 0-1 sans contrainte
  - d. Exemples concrets de formulations
2. Linéarisations
3. Approches Lagrangiennes
4. Approche par Programmation Semidéfinie

## I.b. Modéliser à l'aide de variables 0-1

- b.1 Variables prenant un ensemble fini de valeurs

## I.b. Modéliser à l'aide de variables 0-1

- b.1 Variables prenant un ensemble fini de valeurs
- b.2 Contraintes alternatives/impliquées

## I.b. Modéliser à l'aide de variables 0-1

- b.1 Variables prenant un ensemble fini de valeurs
- b.2 Contraintes alternatives/impliquées
- b.3 Minimum ou maximum de  $k$  fonctions bornées

## I.b. Modéliser à l'aide de variables 0-1

- b.1 Variables prenant un ensemble fini de valeurs
- b.2 Contraintes alternatives/impliquées
- b.3 Minimum ou maximum de  $k$  fonctions bornées
- b.4 Fonctions linéaires par morceaux

## I.b. Modéliser à l'aide de variables 0-1

- b.1 Variables prenant un ensemble fini de valeurs
- b.2 Contraintes alternatives/impliquées
- b.3 Minimum ou maximum de  $k$  fonctions bornées
- b.4 Fonctions linéaires par morceaux
- b.5 Fonctions en escalier

## I.b. Modéliser à l'aide de variables 0-1

- b.1 Variables prenant un ensemble fini de valeurs
- b.2 Contraintes alternatives/impliquées
- b.3 Minimum ou maximum de  $k$  fonctions bornées
- b.4 Fonctions linéaires par morceaux
- b.5 Fonctions en escalier
- b.6 Ratio de fonctions pseudo-booléennes linéaires



# Plan du cours

1. Introduction
  - a. Modèle Général étudié
  - b. Modéliser à l'aide de variables 0-1
  - c. Cas Quadratique 0-1 sans contrainte
  - d. Exemples concrets de formulations
2. Linéarisations
3. Approches Lagrangiennes
4. Approche par Programmation Semidéfinie

# I.c. Cas Quadratique 0-1 sans contrainte

Maximiser  $x^T Qx + b^T x$  avec  $x \in \{0, 1\}^n$


- I.c.1. Exemple de cas difficile : max-Cut  $\geq_p$  NAE-3SAT

# I.c. Cas Quadratique 0-1 sans contrainte

Maximiser  $x^T Qx + b^T x$  avec  $x \in \{0, 1\}^n$


- I.c.1. Exemple de cas difficile : max-Cut  $\geq_p$  NAE-3SAT
- I.c.2. Exemple de cas facile : maximiser avec  $Q_{ij} \geq 0 \Leftrightarrow$  problème de coupe minimale particulier (fonction sous-modulaire)

## I.c.1. Problème max-cut



**Données.** Soit un graphe  $G = (V, X)$  possédant  $n$  sommets et dont les arêtes  $[v_i, v_j]$  sont valuées positivement par une matrice  $W = (W_{ij})$ .


## I.c.1. Problème max-cut



**Données.** Soit un graphe  $G = (V, X)$  possédant  $n$  sommets et dont les arêtes  $[v_i, v_j]$  sont valuées positivement par une matrice  $W = (W_{ij})$ .

**Question.** Trouver une partition des sommets de  $V$  en deux sous-ensembles  $(V_1, V_2)$  telle que la somme des poids des arêtes ayant leurs extrémités dans des paquets différents soit maximale.

## I.c.1. Problème max-cut



**Données.** Soit un graphe  $G = (V, X)$  possédant  $n$  sommets et dont les arêtes  $[v_i, v_j]$  sont valuées positivement par une matrice  $W = (W_{ij})$ .

**Question.** Trouver une partition des sommets de  $V$  en deux sous-ensembles  $(V_1, V_2)$  telle que la somme des poids des arêtes ayant leurs extrémités dans des paquets différents soit maximale.

**Modèle.**

$$\begin{cases} \max \sum_{i < j} w_{ij} [x_i (1 - x_j) + x_j (1 - x_i)] \\ \text{Sous la contrainte : } x \in \{0, 1\}^n \end{cases}$$

## I.c.2. Exemple de cas facile

Maximiser  $x^T Q x + b^T x$  avec  $x \in \{0, 1\}^n$

avec :

- $b_i$  de signe quelconque

## I.c.2. Exemple de cas facile

Maximiser  $x^T Q x + b^T x$  avec  $x \in \{0, 1\}^n$

avec :

- $b_i$  de signe quelconque
- $Q_{ij}$  tous positifs



## I.c.2. Exemple de cas facile

Maximiser  $x^T Q x + b^T x$  avec  $x \in \{0, 1\}^n$

avec :

- $b_i$  de signe quelconque
- $Q_{ij}$  tous positifs

## I.c.2. Exemple de cas facile

Maximiser  $x^T Qx + b^T x$  avec  $x \in \{0, 1\}^n$

avec :

- $b_i$  de signe quelconque
- $Q_{ij}$  tous positifs

=> Construction d'un problème équivalent flot maximal/coupe minimale

# Plan du cours

1. Introduction
  - a. Modèle Général étudié
  - b. Modéliser à l'aide de variables 0-1
  - c. Cas Quadratique 0-1 sans contrainte
  - d. Exemples concrets de formulations
2. Linéarisations
3. Approches Lagrangiennes
4. Approche par Programmation Semidéfinie

# I.d.1. Placement de tâches dans un système distribué

## Données.

- $n$  tâches communicantes et  $p$  processeurs

# I.d.1. Placement de tâches dans un système distribué

## Données.

- $n$  tâches communicantes et  $p$  processeurs
- Une matrice  $C$   $n \times n$  représentant les coûts de communication si les tâches sont placées sur des processeurs différents. Coût de communication négligeable si les tâches sont sur le même processeur

# I.d.1. Placement de tâches dans un système distribué

## Données.

- $n$  tâches communicantes et  $p$  processeurs
- Une matrice  $C$   $n \times n$  représentant les coûts de communication si les tâches sont placées sur des processeurs différents. Coût de communication négligeable si les tâches sont sur le même processeur
- une matrice  $Q$   $n \times p$  représentant les coûts d'exécution

# I.d.1. Placement de tâches dans un système distribué

## Données.

- $n$  tâches communicantes et  $p$  processeurs
- Une matrice  $C$   $n \times n$  représentant les coûts de communication si les tâches sont placées sur des processeurs différents. Coût de communication négligeable si les tâches sont sur le même processeur
- une matrice  $Q$   $n \times p$  représentant les coûts d'exécution

# I.d.1. Placement de tâches dans un système distribué

## Données.

- $n$  tâches communicantes et  $p$  processeurs
- Une matrice  $C$   $n \times n$  représentant les coûts de communication si les tâches sont placées sur des processeurs différents. Coût de communication négligeable si les tâches sont sur le même processeur
- une matrice  $Q$   $n \times p$  représentant les coûts d'exécution

**Question.** Trouver une affectation des tâches sur les processeurs minimisant le coût total (exécution+communications)



# I.d.1. Placement de tâches dans un système distribué

## Modélisation.

$$(P) \left\{ \begin{array}{l} \min \quad \sum_{t=1}^n \sum_{k=1}^p Q_{tk} x_{tk} + \sum_{k=1}^p \sum_{t < t'} C_{tt'} x_{tk} (1 - x_{t'k}) \\ \text{s.c.} : \quad \sum_{k=1}^p x_{tk} = 1 ; t = 1, \dots, n \\ \quad \quad x \in \{0, 1\}^{np} \end{array} \right.$$

# I.d.1. Placement de tâches dans un système distribué

## Modélisation.

$$(P) \left\{ \begin{array}{l} \min \quad \sum_{t=1}^n \sum_{k=1}^P Q_{tk} x_{tk} + \sum_{k=1}^P \sum_{t < t'} C_{tt'} x_{tk} (1 - x_{t'k}) \\ \text{s.c.} : \quad \sum_{k=1}^P x_{tk} = 1 ; t = 1, \dots, n \\ x \in \{0, 1\}^{np} \end{array} \right.$$

Cas  $P = 2$  : polynomial ! (NP-difficile pour  $P \geq 3$ )

## I.d.2. Gestion de personnel

**Objectif** : mettre en place un planning hebdomadaire pour un ensemble de  $n$  personnes en **maximisant le nombre de jours de congés consécutifs**

## I.d.2. Gestion de personnel

**Objectif** : mettre en place un planning hebdomadaire pour un ensemble de  $n$  personnes en **maximisant le nombre de jours de congés consécutifs**

**Contraintes** :

- $n_j$  personnes sont nécessaires le jour  $j$  ( $j = 1, \dots, 7$ ).

## I.d.2. Gestion de personnel

**Objectif** : mettre en place un planning hebdomadaire pour un ensemble de  $n$  personnes en **maximisant le nombre de jours de congés consécutifs**

**Contraintes** :

- $n_j$  personnes sont nécessaires le jour  $j$  ( $j = 1, \dots, 7$ ).
- La personne  $i$  prend  $T_i$  jours de congés par semaine.

## I.d.2. Gestion de personnel

$$\left\{ \begin{array}{l} \max \quad \sum_{i=1}^n \left( \sum_{j=1}^6 x_{ij} x_{ij+1} + x_{i7} x_{i1} \right) \\ \text{s.c.} \quad \sum_{i=1}^n x_{ij} = n - n_j \quad j = 1, \dots, 7 \\ \quad \quad \sum_{j=1}^7 x_{ij} = T_i \quad i = 1, \dots, n \\ \quad \quad x_{ij} \in \{0, 1\} \quad i = 1, \dots, n, j = 1, \dots, 7 \end{array} \right.$$

## I.d.3. Gestion de Stocks

- $n$  type d'articles à réapprovisionner dont les demandes par unité de temps sont connues

## I.d.3. Gestion de Stocks

- $n$  type d'articles à réapprovisionner dont les demandes par unité de temps sont connues
- $R$  : nombre maximal de réapprovisionnements par unité de temps



## I.d.3. Gestion de Stocks

- $n$  type d'articles à réapprovisionner dont les demandes par unité de temps sont connues
- $R$  : nombre maximal de réapprovisionnements par unité de temps
- $C_i$  : coût de stockage par unité de temps pour les articles de type  $i$

## I.d.3. Gestion de Stocks

- $n$  type d'articles à réapprovisionner dont les demandes par unité de temps sont connues
- $R$  : nombre maximal de réapprovisionnements par unité de temps
- $C_j$  : coût de stockage par unité de temps pour les articles de type  $i$
- $\Delta_1, \dots, \Delta_m$  : intervalles de temps possibles entre deux commandes successives d'un article de même type

## I.d.3. Gestion de Stocks

- $n$  type d'articles à réapprovisionner dont les demandes par unité de temps sont connues
- $R$  : nombre maximal de réapprovisionnements par unité de temps
- $C_i$  : coût de stockage par unité de temps pour les articles de type  $i$
- $\Delta_1, \dots, \Delta_m$  : intervalles de temps possibles entre deux commandes successives d'un article de même type
- Choisir un intervalle de temps  $\delta_i$  pour commander chaque type d'article

## I.d.4. Gestion de Stocks

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n C_i \delta_i \\ \text{s.c.} \quad \sum_{i=1}^n \frac{1}{\delta_i} \leq R \\ \delta_i \in \{\Delta_1, \dots, \Delta_m\} \quad i = 1, \dots, n \end{array} \right.$$

## I.d.4. Gestion de Stocks

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n C_i \delta_i \\ \text{s.c.} \quad \sum_{i=1}^n \frac{1}{\delta_i} \leq R \\ \delta_i \in \{\Delta_1, \dots, \Delta_m\} \quad i = 1, \dots, n \end{array} \right.$$

=> Programme non quadratique, et variables non 0-1 !

## I.d.4. Gestion de Stocks

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n C_i \delta_i \\ \text{s.c.} \quad \sum_{i=1}^n \frac{1}{\delta_i} \leq R \\ \delta_i \in \{\Delta_1, \dots, \Delta_m\} \quad i = 1, \dots, n \end{array} \right.$$

=> Programme non quadratique, et variables non 0-1 !

Réécriture :

$$\delta_i = \sum_{j=1}^m \Delta_j z_{ij} \Rightarrow \frac{1}{\delta_i} = \sum_{j=1}^m \frac{1}{\Delta_j} z_{ij}$$

avec  $z_{ij} \in \{0, 1\}$  et  $\sum_{j=1}^m z_{ij} = 1$

## I.d.4. Gestion de Stocks

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n C_i \delta_i \\ \text{s.c.} \quad \sum_{i=1}^n \frac{1}{\delta_i} \leq R \\ \delta_i \in \{\Delta_1, \dots, \Delta_m\} \quad i = 1, \dots, n \end{array} \right.$$

=> Programme non quadratique, et variables non 0-1 !

Réécriture :

$$\delta_i = \sum_{j=1}^m \Delta_j z_{ij} \Rightarrow \frac{1}{\delta_i} = \sum_{j=1}^m \frac{1}{\Delta_j} z_{ij}$$

avec  $z_{ij} \in \{0, 1\}$  et  $\sum_{j=1}^m z_{ij} = 1$

=>

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n C_i \sum_{j=1}^m \Delta_j z_{ij} \\ \text{s.c.} \quad \sum_{i=1}^n \sum_{j=1}^m \frac{1}{\Delta_j} z_{ij} \leq R \\ \sum_{j=1}^m z_{ij} = 1 \\ z_{ij} \in \{0, 1\} \quad i = 1, \dots, n \quad j = 1, \dots, m \end{array} \right.$$

## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$



## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$

- $\Gamma$  : matrice des variances/co-variances

## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$

- $\Gamma$  : matrice des variances/co-variances
- $r_i$  : espérance du rendement de l'action  $i$

## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$

- $\Gamma$  : matrice des variances/co-variances
- $r_i$  : espérance du rendement de l'action  $i$
- $x_i$  : proportion du titre  $i$  dans le portefeuille

## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$

- $\Gamma$  : matrice des variances/co-variances
- $r_i$  : espérance du rendement de l'action  $i$
- $x_i$  : proportion du titre  $i$  dans le portefeuille

## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$

- $\Gamma$  : matrice des variances/co-variances
- $r_i$  : espérance du rendement de l'action  $i$
- $x_i$  : proportion du titre  $i$  dans le portefeuille

$$\text{(Markovitz)} \quad \left\{ \begin{array}{l} \min \quad x^T \Gamma x = \sum_{i=1}^n \sum_{j=1}^n \Gamma_{ij} x_i x_j \\ \text{s.c.} \quad \sum_{i=1}^n x_i = 1 \\ \quad \quad \sum_{i=1}^n r_i x_i = \rho \\ \quad \quad x \in [0, 1]^n \end{array} \right.$$

## I.d.5. Constitution d'un portefeuille d'actions

Choisir  $m$  actions parmi  $n$  en minimisant le risque et en garantissant un rendement global égal à une valeur fixée  $\rho$

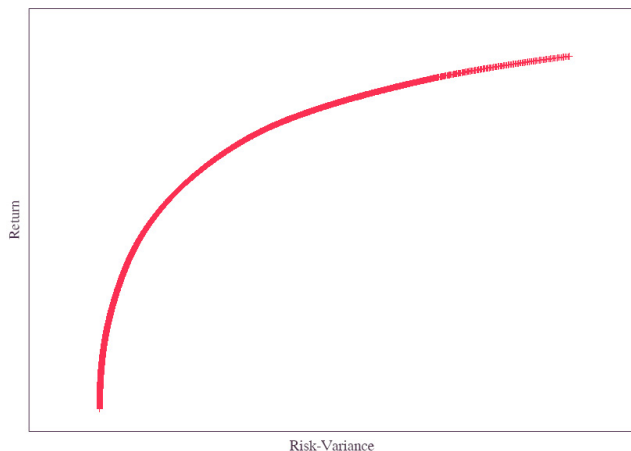
- $\Gamma$  : matrice des variances/co-variances
- $r_i$  : espérance du rendement de l'action  $i$
- $x_i$  : proportion du titre  $i$  dans le portefeuille

$$\text{(Markovitz)} \quad \left\{ \begin{array}{l} \min \quad x^T \Gamma x = \sum_{i=1}^n \sum_{j=1}^n \Gamma_{ij} x_i x_j \\ \text{s.c.} \quad \sum_{i=1}^n x_i = 1 \\ \quad \quad \sum_{i=1}^n r_i x_i = \rho \\ \quad \quad x \in [0, 1]^n \end{array} \right.$$

Problème quadratique convexe continu : **facile** à résoudre

# Frontière d'efficience

En faisant varier la valeur du rendement souhaité, on obtient une **frontière d'efficience** continue et convexe !



## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

Soyons plus **réalistes** :

- Limitation du nombre de titres :  $\sum_{i=1}^n y_i = m$  avec  $y \in \{0, 1\}^n$ , i.e. l'action  $i$  fait partie du portefeuille



## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

Soyons plus **réalistes** :

- Limitation du nombre de titres :  $\sum_{i=1}^n y_i = m$  avec  $y \in \{0, 1\}^n$ , i.e. l'action  $i$  fait partie du portefeuille
- Limitation des quantités de chaque action :  $LB_i y_i \leq x_i \leq UB_i y_i$

## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

Soyons plus **réalistes** :

- Limitation du nombre de titres :  $\sum_{i=1}^n y_i = m$  avec  $y \in \{0, 1\}^n$ , i.e. l'action  $i$  fait partie du portefeuille
- Limitation des quantités de chaque action :  $LB_i y_i \leq x_i \leq UB_i y_i$
- Achat des actions par fraction fixée  $f_i$  :  $x_i = f_i z_i$ , où  $z_i \in \mathbb{N}$

## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

Soyons plus **réalistes** :

- Limitation du nombre de titres :  $\sum_{i=1}^n y_i = m$  avec  $y \in \{0, 1\}^n$ , i.e. l'action  $i$  fait partie du portefeuille
- Limitation des quantités de chaque action :  $LB_i y_i \leq x_i \leq UB_i y_i$
- Achat des actions par fraction fixée  $f_i$  :  $x_i = f_i z_i$ , où  $z_i \in \mathbb{N}$

## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

Soyons plus **réalistes** :

- Limitation du nombre de titres :  $\sum_{i=1}^n y_i = m$  avec  $y \in \{0, 1\}^n$ , i.e. l'action  $i$  fait partie du portefeuille
- Limitation des quantités de chaque action :  $LB_i y_i \leq x_i \leq UB_i y_i$
- Achat des actions par fraction fixée  $f_i$  :  $x_i = f_i z_i$ , où  $z_i \in \mathbb{N}$

=> Modèle **discret** : beaucoup plus difficile à résoudre !

## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

$$\left\{ \begin{array}{l} \min \quad x^T \Gamma x = \sum_{i=1}^n \sum_{j=1}^n \Gamma_{ij} x_i x_j \\ \text{s.c.} \quad \sum_{i=1}^n x_i = 1 \\ \quad \quad \sum_{i=1}^n r_i x_i = \rho \\ \quad \quad \sum_{i=1}^n y_i = m \\ \quad \quad LB_i y_i \leq x_i \leq UB_i y_i \quad i = 1, \dots, n \\ \quad \quad x \in [0, 1]^n, y \in \{0, 1\}^n \end{array} \right.$$

## I.d.6. Constitution d'un portefeuille d'actions (plus réaliste)

$$\left\{ \begin{array}{l} \min \quad x^T \Gamma x = \sum_{i=1}^n \sum_{j=1}^n \Gamma_{ij} x_i x_j \\ \text{s.c.} \quad \sum_{i=1}^n x_i = 1 \\ \quad \quad \sum_{i=1}^n r_i x_i = \rho \\ \quad \quad \sum_{i=1}^n y_i = m \\ \quad \quad LB_i y_i \leq x_i \leq UB_i y_i \quad \quad i = 1, \dots, n \\ \quad \quad x \in [0, 1]^n, y \in \{0, 1\}^n \end{array} \right.$$

=> **Idee** : énumérer sur  $y$  pour retrouver un programme quadratique convexe continu !

# Frontière d'efficience dans le cas discret (1)

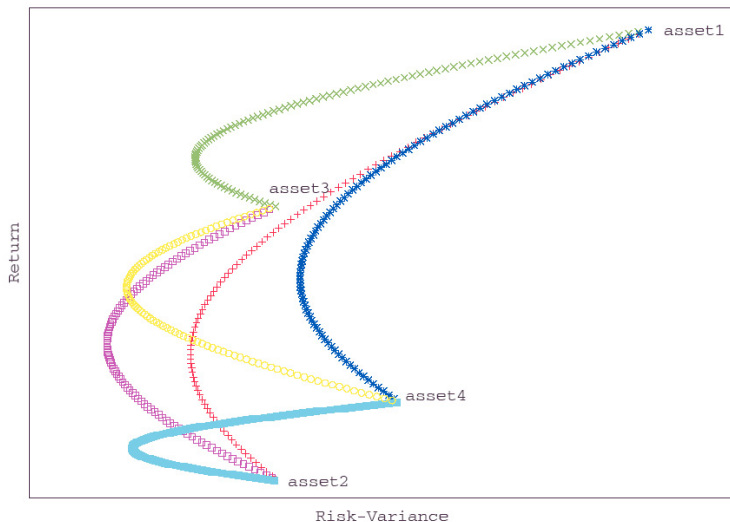
**Exemple.** Choisir 2 titres parmi 4 :  $\sum_{i=1}^4 y_i = 2$  avec  $y \in \{0, 1\}^4$

Titre	Espérance de rendement	Ecart-type
1	0.004798	0.046341
2	0.000659	0.035770
3	0.003174	0.030474
4	0.001377	0.035770

$$\begin{pmatrix} 0.118368 & 0.143822 & 0.252213 \\ & 0.164589 & 0.099763 \\ & & 0.083122 \end{pmatrix}$$

## Frontière d'efficacité dans le cas discret (2)

Pour chaque couple de titres parmi les quatre, on peut tracer la frontière d'efficacité :





## Frontière d'efficacité dans le cas discret (3)

Pour un risque donné, on prend le meilleur rendement : frontière non convexe et même discontinue !



Risk-Variance

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final
- Minimiser : le risque +  $\alpha \times$  les coûts fixes et linéaires de transaction (commissions, courtage, taxes)

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final
- Minimiser : le risque +  $\alpha \times$  les coûts fixes et linéaires de transaction (commissions, courtage, taxes)
- Coûts linéaires :  $a_i$  et  $v_i$  représentent respectivement les volumes de vente et d'achat de l'action  $i$

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final
- Minimiser : le risque +  $\alpha \times$  les coûts fixes et linéaires de transaction (commissions, courtage, taxes)
- Coûts linéaires :  $a_i$  et  $v_i$  représentent respectivement les volumes de vente et d'achat de l'action  $i$
- Coûts fixes  $c_i^F y_i$  :  $y_i = 1$  si  $x_i \neq x_i^0$  et sinon  $y_i = 0$

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final
- Minimiser : le risque +  $\alpha \times$  les coûts fixes et linéaires de transaction (commissions, courtage, taxes)
- Coûts linéaires :  $a_i$  et  $v_i$  représentent respectivement les volumes de vente et d'achat de l'action  $i$
- Coûts fixes  $c_i^F y_i$  :  $y_i = 1$  si  $x_i \neq x_i^0$  et sinon  $y_i = 0$
- Pour l'action  $i$  :  $C_i = c_i^F y_i + c_i^A a_i + c_i^V v_i$

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final
- Minimiser : le risque +  $\alpha \times$  les coûts fixes et linéaires de transaction (commissions, courtage, taxes)
- Coûts linéaires :  $a_i$  et  $v_i$  représentent respectivement les volumes de vente et d'achat de l'action  $i$
- Coûts fixes  $c_i^F y_i$  :  $y_i = 1$  si  $x_i \neq x_i^0$  et sinon  $y_i = 0$
- Pour l'action  $i$  :  $C_i = c_i^F y_i + c_i^A a_i + c_i^V v_i$

## I.d.7. Problème du rééquilibrage d'un portefeuille

- $x^0$  : portefeuille initial,  $x$  : portefeuille final
- Minimiser : le risque +  $\alpha \times$  les coûts fixes et linéaires de transaction (commissions, courtage, taxes)
- Coûts linéaires :  $a_i$  et  $v_i$  représentent respectivement les volumes de vente et d'achat de l'action  $i$
- Coûts fixes  $c_i^F y_i$  :  $y_i = 1$  si  $x_i \neq x_i^0$  et sinon  $y_i = 0$
- Pour l'action  $i$  :  $C_i = c_i^F y_i + c_i^A a_i + c_i^V v_i$

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n \sum_{j=1}^n \Gamma_{ij} x_i x_j + \alpha \sum_{i=1}^n C_i \\ \text{s.c.} \quad \sum_{i=1}^n x_i = 1 \\ \quad \sum_{i=1}^n r_i x_i \geq \rho \\ \quad a_i \leq y_i (UB_i - x_i^0), \quad a_i \geq x_i - x_i^0, \quad a_i \geq 0 \quad i = 1, \dots, n \\ \quad v_i \leq y_i (x_i^0 - LB_i), \quad v_i \geq x_i^0 - x_i, \quad v_i \geq 0 \quad i = 1, \dots, n \\ \quad LB_i y_i \leq x_i \leq UB_i y_i \\ \quad x \in [0, 1]^n, \quad y \in \{0, 1\}^n \end{array} \right.$$



# Plan du cours

## 1. Introduction

## 2. Linéarisations

- a. Linéarisation "Classique"
- b. Linéarisation "Produit"
- c. Linéarisations "Compactes"
- d. Application au problème du sac-à-dos quadratique

## 3. Approches Lagrangiennes

## 4. Approche par Programmation Semidéfinie

# Plan du cours

## 1. Introduction

## 2. Linéarisations

- a. Linéarisation "Classique"
- b. Linéarisation "Produit"
- c. Linéarisations "Compactes"
- d. Application au problème du sac-à-dos quadratique

## 3. Approches Lagrangiennes

## 4. Approche par Programmation Semidéfinie

## 2.a. Linéarisation classique (Dantzig)

Programmation Quadratique en variables 0-1

$$(Q) \quad \left\{ \begin{array}{l} \min_{x \in \mathbb{R}^n} \quad x^T Q x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ \quad \quad Ax = (\text{ou } \leq) b \\ \quad \quad x \in \{0, 1\}^n \end{array} \right.$$

## 2.a. Linéarisation classique (Dantzig)

Programmation Quadratique en variables 0-1

$$(Q) \quad \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

Linéarisation :

- Remplacer  $x_i x_j$  par  $Y_{ij} \forall i < j$

## 2.a. Linéarisation classique (Dantzig)

Programmation Quadratique en variables 0-1

$$(Q) \quad \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

Linéarisation :

- Remplacer  $x_i x_j$  par  $Y_{ij} \forall i < j$
- Ajouter :  $Y_{ij} \leq x_i$ ,  $Y_{ij} \leq x_j$ , et  $Y_{ij} - x_i - x_j + 1 \geq 0 \forall i < j$

## 2.a. Linéarisation classique (Dantzig)

Programmation Quadratique en variables 0-1

$$(Q) \quad \left\{ \begin{array}{l} \min_{x \in \mathbb{R}^n} \quad x^T Q x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j \\ \text{s.c.} \quad \quad \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ \quad \quad \quad \quad \quad Ax = (\text{ou } \leq) b \\ \quad \quad \quad \quad \quad x \in \{0, 1\}^n \end{array} \right.$$

Linéarisation :

- Remplacer  $x_i x_j$  par  $Y_{ij} \forall i < j$
- Ajouter :  $Y_{ij} \leq x_i$ ,  $Y_{ij} \leq x_j$ , et  $Y_{ij} - x_i - x_j + 1 \geq 0 \forall i < j$
- **Relaxation** : Remplacer  $x \in \{0, 1\}^n$  par  $0 \leq x_i \leq 1 \forall i$

## 2.a. Linéarisation classique (Dantzig)

Programmation Quadratique en variables 0-1

$$(Q) \quad \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

Linéarisation :

- Remplacer  $x_i x_j$  par  $Y_{ij} \forall i < j$
- Ajouter :  $Y_{ij} \leq x_i$ ,  $Y_{ij} \leq x_j$ , et  $Y_{ij} - x_i - x_j + 1 \geq 0 \forall i < j$
- **Relaxation** : Remplacer  $x \in \{0, 1\}^n$  par  $0 \leq x_i \leq 1 \forall i$

## 2.a. Linéarisation classique (Dantzig)

Programmation Quadratique en variables 0-1

$$(Q) \quad \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x = \sum_{i=1}^n \sum_{j=1}^n Q_{ij} x_i x_j \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Ax = (\text{ou } \leq) b \\ & x \in \{0, 1\}^n \end{cases}$$

Linéarisation :

- Remplacer  $x_i x_j$  par  $Y_{ij} \forall i < j$
- Ajouter :  $Y_{ij} \leq x_i$ ,  $Y_{ij} \leq x_j$ , et  $Y_{ij} - x_i - x_j + 1 \geq 0 \forall i < j$
- **Relaxation** : Remplacer  $x \in \{0, 1\}^n$  par  $0 \leq x_i \leq 1 \forall i$

=> Programme linéaire continu



## 2.a. Linéarisation classique (Dantzig)

(PL\_D)

$$\left\{ \begin{array}{ll} \min & \sum_{i=1}^n \sum_{j=1}^n Q_{ij} Y_{ij} \\ \text{s.c.} & \sum_{i=1}^n \sum_{j=1}^n B_{ij} Y_{ij} + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ & Y_{ij} \leq x_i, Y_{ij} \leq x_j \quad i < j \in \{1, \dots, n\} \\ & Y_{ij} - x_i - x_j + 1 \geq 0 \quad i < j \in \{1, \dots, n\} \\ & Ax = (\text{ou } \leq) b \\ & x \in [0, 1]^n \quad Y_{ij} \geq 0 \forall i < j \in \{1, \dots, n\} \end{array} \right.$$

## 2.a. Linéarisation classique (Dantzig)

(PL\_D)

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n \sum_{j=1}^n Q_{ij} Y_{ij} \\ \text{s.c.} \quad \sum_{i=1}^n \sum_{j=1}^n B_{ij} Y_{ij} + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ \quad \quad Y_{ij} \leq x_i, Y_{ij} \leq x_j \quad i < j \in \{1, \dots, n\} \\ \quad \quad Y_{ij} - x_i - x_j + 1 \geq 0 \quad i < j \in \{1, \dots, n\} \\ \quad \quad Ax = (\text{ou } \leq) b \\ \quad \quad x \in [0, 1]^n \quad Y_{ij} \geq 0 \forall i < j \in \{1, \dots, n\} \end{array} \right.$$

Coût élevé :  $O(n^2)$  variables et contraintes supplémentaires

# Plan du cours

## 1. Introduction

## 2. Linéarisations

- a. Linéarisation "Classique"
- b. Linéarisation "Produit"
- c. Linéarisations "Compactes"
- d. Application au problème du sac-à-dos quadratique

## 3. Approches Lagrangiennes

## 4. Approche par Programmation Semidéfinie

## 2.b. Linéarisation "Produit" (Adams-Sherali)

On multiplie  $Ax \leq b$  par  $x_k$  et par  $1 - x_k$  pour tout  $k$  dans  $\{1, \dots, n\}$

## 2.b. Linéarisation "Produit" (Adams-Sherali)

On multiplie  $Ax \leq b$  par  $x_k$  et par  $1 - x_k$  pour tout  $k$  dans  $\{1, \dots, n\}$   
(PL\_AS)

$$\left\{ \begin{array}{l} \min \quad \sum_{i=1}^n \sum_{j=1}^n Q_{ij} Y_{ij} \\ \text{s.c.} \quad \sum_{i=1}^n \sum_{j=1}^n B_{ij} Y_{ij} + d_i^T x = (\text{ou } \leq) e_i \quad i \in \{1, \dots, m\} \\ Y_{ij} \leq x_i, Y_{ij} \leq x_j \quad i < j \in \{1, \dots, n\} \\ Y_{ij} - x_i - x_j + 1 \geq 0 \quad i < j \in \{1, \dots, n\} \\ \sum_{j=1}^{k-1} A_j Y_{jk} + \sum_{j=k+1}^n A_j Y_{kj} (\text{ou } \leq) (b - A_k) x_k \quad \forall k \\ \sum_{j=1}^{k-1} A_j (x_k - Y_{jk}) + \sum_{j=k+1}^n A_j (x_k - Y_{kj}) (\text{ou } \leq) b(1 - x_k) \quad \forall k \\ x \in [0, 1]^n \quad Y_{ij} \geq 0 \end{array} \right.$$

# Plan du cours

## 1. Introduction

## 2. Linéarisations

- a. Linéarisation "Classique"
- b. Linéarisation "Produit"
- c. Linéarisations "Compactes"
- d. Application au problème du sac-à-dos quadratique

## 3. Approches Lagrangiennes

## 4. Approche par Programmation Semidéfinie

## 2.c. Linéarisations "Compactes" (Glover)

- Facteur de  $x_i$  dans la fonction quadratique :  $L_i(x) = \sum_{j=i+1}^n Q_{ij}x_j$

## 2.c. Linéarisations "Compactes" (Glover)

- Facteur de  $x_i$  dans la fonction quadratique :  $L_i(x) = \sum_{j=i+1}^n Q_{ij}x_j$
- on détermine :  $\alpha_j \leq L_i(x) \leq \beta_j$



## 2.c. Linéarisations "Compactes" (Glover)

- Facteur de  $x_i$  dans la fonction quadratique :  $L_i(x) = \sum_{j=i+1}^n Q_{ij}x_j$
- on détermine :  $\alpha_i \leq L_i(x) \leq \beta_i$
- Pour tout  $i$  dans  $\{1, \dots, n\}$ ,  $x_i L_i(x)$  est représenté par une variable  $z_i$

## 2.c. Linéarisations "Compactes" (Glover)

- Facteur de  $x_i$  dans la fonction quadratique :  $L_i(x) = \sum_{j=i+1}^n Q_{ij}x_j$
- on détermine :  $\alpha_i \leq L_i(x) \leq \beta_i$
- Pour tout  $i$  dans  $\{1, \dots, n\}$ ,  $x_i L_i(x)$  est représenté par une variable  $z_i$

## 2.c. Linéarisations "Compactes" (Glover)

- Facteur de  $x_i$  dans la fonction quadratique :  $L_i(x) = \sum_{j=i+1}^n Q_{ij}x_j$
- on détermine :  $\alpha_i \leq L_i(x) \leq \beta_i$
- Pour tout  $i$  dans  $\{1, \dots, n\}$ ,  $x_i L_i(x)$  est représenté par une variable  $z_i$

Contraintes :

- $\alpha_i x_i \leq z_i \leq \beta_i x_i$

## 2.c. Linéarisations "Compactes" (Glover)

- Facteur de  $x_i$  dans la fonction quadratique :  $L_i(x) = \sum_{j=i+1}^n Q_{ij}x_j$
- on détermine :  $\alpha_i \leq L_i(x) \leq \beta_i$
- Pour tout  $i$  dans  $\{1, \dots, n\}$ ,  $x_i L_i(x)$  est représenté par une variable  $z_i$

### Contraintes :

- $\alpha_i x_i \leq z_i \leq \beta_i x_i$
- $L_i(x) - \beta_i(1 - x_i) \leq z_i \leq L_i(x) - \alpha_i(1 - x_i)$

# Plan du cours

## 1. Introduction

## 2. Linéarisations

- a. Linéarisation "Classique"
- b. Linéarisation "Produit"
- c. Linéarisations "Compactes"
- d. Application au problème du sac-à-dos quadratique

## 3. Approches Lagrangiennes

## 4. Approche par Programmation Semidéfinie

# Application au problème du sac-à-dos quadratique

- Ecriture de différentes relaxations linéaires

# Application au problème du sac-à-dos quadratique

- Ecriture de différentes relaxations linéaires
- Comparaison des relaxations

# Application au problème du sac-à-dos quadratique

- Ecriture de différentes relaxations linéaires
- Comparaison des relaxations
- Amélioration des relaxations compactes



# Plan du cours

1. Introduction
2. Linéarisations
- 3. Approches Lagrangiennes**
  - a. Relaxations Lagrangiennes
  - b. Méthodes de décomposition Lagrangienne
4. Approche par Programmation Semidéfinie

# Plan du cours

1. Introduction
2. Linéarisations
- 3. Approches Lagrangiennes**
  - a. Relaxations Lagrangiennes
  - b. Méthodes de décomposition Lagrangienne
4. Approche par Programmation Semidéfinie

# Plan du cours

1. Introduction
2. Linéarisations
- 3. Approches Lagrangiennes**
  - a. Relaxations Lagrangiennes
  - b. Méthodes de décomposition Lagrangienne
4. Approche par Programmation Semidéfinie

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

**4. Approche par Programmation Semidéfinie**

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

# Plan du cours

1. Introduction
2. Linéarisations
3. Approches Lagrangiennes
- 4. Approche par Programmation Semidéfinie**
  - a. Bases de la Programmation Semidéfinie
  - b. Application à la Programmation Quadratique en 0-1
    - 1. Le nombre de Lovász
    - 2. Relaxation SDP en  $\{0, 1\}$
    - 3. Relaxation SDP en  $\{-1, 1\}$
    - 4. Liens avec l'approche Lagrangienne
    - 5. Amélioration des relaxations Quadratiques Convexes
    - 6. Problèmes SDLS et contrainte sphérique

# Généralités

- Utilisation récente en optimisation combinatoire (1993).

# Généralités

- Utilisation récente en optimisation combinatoire (1993).
- Cas particulier de programmation convexe non-linéaire (fonction et contraintes convexes).

# Généralités

- Utilisation récente en optimisation combinatoire (1993).
- Cas particulier de programmation convexe non-linéaire (fonction et contraintes convexes).
- Généralisation de la programmation linéaire (tout PL est un SDP particulier).



# Généralités

- Utilisation récente en optimisation combinatoire (1993).
- 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.

# Généralités

- Utilisation récente en optimisation combinatoire (1993).
- 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.

# Généralités

- Utilisation récente en optimisation combinatoire (1993).
- 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.
  - ▶ => A réserver aux problèmes très difficiles (lorsque l’approche par PL échoue).

# Matrices (Semidéfinies) Positives

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

# Matrices (Semidéfinies) Positives

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

Produit scalaire dans  $S_n$  :

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

# 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  $x \in \mathbb{R}^n$

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

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

# 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 principaux de $A$ sont $> 0$

# 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 principaux de $A$ sont $> 0$

## Matrices positives (semidéfinies positives)

$A \succeq 0$
$\forall z \in \mathbb{R}^n \quad z^T A z \geq 0$
Les valeurs propres de $A$ sont $\geq 0$
Les mineurs symétriques de $A$ sont $\geq 0$

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



## 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

## 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*

## 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*

## 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  $1 \times 1$  :  $1 \geq 0, 6 \geq 0, 3 \geq 0$

## 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  $2 \times 2$  :  $6 - 4 \geq 0, 18 - 16 \geq 0, 3 - 1 \geq 0$

## 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  $3 \times 3$  :  $\det(A) = 0 \geq 0$

# Inégalités matricielles linéaires

## Definition

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

# Inégalités matricielles linéaires

## Definition

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



# Inégalités matricielles linéaires

## Definition

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

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

# Inégalités matricielles linéaires

## Definition

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

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

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

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

# Inégalités matricielles linéaires

## Definition

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

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

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

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

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

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

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

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


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

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

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

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

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




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

**Exemple 2.** Soit  $x$  et  $t$  réels vérifiant  $\begin{bmatrix} x & 1 \\ 1 & t \end{bmatrix} \succeq 0$

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

**Exemple 2.** Soit  $x$  et  $t$  réels vérifiant  $\begin{bmatrix} x & 1 \\ 1 & t \end{bmatrix} \succeq 0$   
 $\iff x \geq 0, t \geq 0, xt \geq 1$  (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  $n \times n$

## Inégalités matricielles linéaires (2)

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

## Inégalités matricielles linéaires (2)

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

## Inégalités matricielles linéaires (2)

- Soient  $A_0, A_1, \dots, A_m$  dans  $S_n$ , espace des matrices réelles symétriques  $n \times n$
- Pour  $x \in \mathfrak{R}^m$  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

## Inégalités matricielles linéaires (2)

- Soient  $A_0, A_1, \dots, A_m$  dans  $S_n$ , espace des matrices réelles symétriques  $n \times n$
- Pour  $x \in \mathfrak{R}^m$  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

## Inégalités matricielles linéaires (2)

- Soient  $A_0, A_1, \dots, A_m$  dans  $S_n$ , espace des matrices réelles symétriques  $n \times n$
- Pour  $x \in \mathfrak{R}^m$  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)

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

## Inégalités matricielles linéaires (3)

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

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



## Inégalités matricielles linéaires (3)

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

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

## Inégalités matricielles linéaires (3)

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

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 :

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

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

## Inégalités matricielles linéaires (3)

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

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 :

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

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

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

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


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

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

## Théorème

$$\circ$$

$$S = \{x \mid F(x) \succ 0\} \text{ et } \bar{S} = \{x \mid F(x) \succeq 0 \text{ et } \det F(x) = 0\}$$



## 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  $F(x)$ ).

$\Rightarrow$  On obtient des surfaces algébriques (en  $PL$  : hyperplans)

## 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  $F(x)$ ).

$\Rightarrow$  On obtient des surfaces algébriques (en  $PL$  : hyperplans)

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

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


## 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  $F(x)$ ).

$\Rightarrow$  On obtient des surfaces algébriques (en  $PL$  : hyperplans)

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

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  $\mathcal{R}^m$  soumise à une inégalité matricielle linéaire

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



# Programmes Semidéfinis

## Definition

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

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

# Programmes Semidéfinis

## Definition

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

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

## Proposition

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

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

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

# Formulation d'un PL en PSD

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

# Formulation d'un PL en PSD

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

**Exemple.**

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

# Formulation d'un PL en PSD

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

**Exemple.**

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

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

# Compléments de Schur

## Théorème

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

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

# Compléments de Schur

## Théorème

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

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

# Compléments de Schur

## Théorème

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

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

**Preuve.**

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



# Compléments de Schur

## Théorème

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

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

**Preuve.**

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

Cas particuliers importants :

- $A = I_p$ . On a  $\begin{bmatrix} I_p & B \\ B^T & C \end{bmatrix} \succeq 0 \Leftrightarrow C - B^T B \succeq 0$

# Compléments de Schur

## Théorème

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

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

**Preuve.**

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

Cas particuliers importants :

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

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

# 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  $d^T x > 0$ .

# 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  $d^T x > 0$ .

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

# 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

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

# 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.

# 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 :

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

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

- 1 Modéliser ce problème comme un programme linéaire.

# 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

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

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**

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

# 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**

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

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

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

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

## 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 :

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

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

## Utilisation de la même idée en PL

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

est équivalent à

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

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

# Dualité

- Le programme dual de (SDP) est

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

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

# 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**



# 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 **multiplicateur 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  $\lambda \geq 0$

# 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 **multiplicateur 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 :

# 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 **multiplicateur 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  $\inf_{x \in \mathbb{R}^m} L(x, Z) = A_0 \bullet Z$

# 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 **multiplicateur 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  $\inf_{x \in \mathbb{R}^m} L(x, Z) = -\infty$

# Dualité

- Le programme dual de (SDP) est

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

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

- ▶ Le **multiplicateur de Lagrange**  $Z$  associé à l'**inégalité** matricielle linéaire  $F(x) \succeq 0$  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 :

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

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \Re^m$

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \Re^m$
- Dans le **dual** : variable  $Z \in S_n$



# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \mathbb{R}^m$
- Dans le **dual** : variable  $Z \in \mathcal{S}_n$
- $F(x)$  et  $Z$  appartiennent à l'intersection d'un espace affine (pas le même !) et du cône des matrices positives

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \mathbb{R}^m$
- Dans le **dual** : variable  $Z \in \mathcal{S}_n$
- $F(x)$  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  $\mathcal{N}_0 = \{Z ; Z \in \mathcal{S}_n, A_i \bullet Z = c_i, i = 1, \dots, p\}$

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \mathbb{R}^m$
- Dans le **dual** : variable  $Z \in \mathcal{S}_n$
- $F(x)$  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  $\mathcal{N}_0 = \{Z ; Z \in \mathcal{S}_n, A_i \bullet Z = c_i, i = 1, \dots, p\}$
- $Z = F(y) = -B_0 + \sum_{i=1}^p y_i B_i$

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \mathbb{R}^m$
- Dans le **dual** : variable  $Z \in \mathcal{S}_n$
- $F(x)$  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  $\mathcal{N}_0 = \{Z ; Z \in \mathcal{S}_n, A_i \bullet Z = c_i, i = 1, \dots, p\}$
- $Z = F(y) = -B_0 + \sum_{i=1}^p y_i B_i$

# Formes Duale et Primale

(DSDP) est-il bien un programme semidéfini ?

- Dans le **primal** : variable  $x \in \mathfrak{R}^m$
- Dans le **dual** : variable  $Z \in \mathcal{S}_n$
- $F(x)$  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  $\mathfrak{N}_0 = \{Z ; Z \in \mathcal{S}_n, A_i \bullet Z = c_i, i = 1, \dots, p\}$
- $Z = F(y) = -B_0 + \sum_{i=1}^p y_i B_i$

On peut réécrire (DSDP) sous une **forme** primale :

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

# 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  $AB = 0$*

# 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  $AB = 0$*

# 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 :



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

# 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 :  $\exists x / F(x) \succ 0$ ).

# 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 ( $\exists Z / Z = Z^T \succ 0, A_i \bullet Z = c_i, i = 1, \dots, m$ )

# 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

# Conditions des écarts complémentaires en PSD

## 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 :

$$F(x) \succeq 0$$

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

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

# Conditions des écarts complémentaires en PSD

## 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 :*

$$F(x) \succeq 0$$

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

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

# Conditions des écarts complémentaires en PSD

## 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**

# Conditions des écarts complémentaires en PSD

## 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  $Z_{ii} \mathbf{diag}(Ax - b)_{ii} = Z_{ii} (A_i^T x - b_i) = 0 \forall i$



## 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.

## Exemple d'application

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

- 1 Résoudre ( $SDP$ ), i.e. donner sa valeur optimale ainsi que l'ensemble des solutions optimales.
- 2 Ecrire ( $DSDP$ ), le programme dual de ( $SDP$ ).

## 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.

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

**4. Approche par Programmation Semidéfinie**

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

**4. Approche par Programmation Semidéfinie**

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

## 4.b.1. Le nombre de Lovász

### Le problème du STABLE

**Données.** Un  $G = (V, E)$  un graphe non orienté possédant  $n$  sommets.

**Question.** Trouver un ensemble  $S$  de sommets de cardinalité maximale tel que le sous-graphe induit par  $S$  ne possède pas d'arête (stable de  $G$ ).

## 4.b.1. Le nombre de Lovász

### Le problème du STABLE

**Données.** Un  $G = (V, E)$  un graphe non orienté possédant  $n$  sommets.

**Question.** Trouver un ensemble  $S$  de sommets de cardinalité maximale tel que le sous-graphe induit par  $S$  ne possède pas d'arête (stable de  $G$ ).

- Soit  $\mathfrak{M}(G) = \{A \in S_n : A_{ij} = 1 \text{ si } (i, j) \notin E \text{ ou } (i = j)\}$

## 4.b.1. Le nombre de Lovász

### Le problème du STABLE

**Données.** Un  $G = (V, E)$  un graphe non orienté possédant  $n$  sommets.

**Question.** Trouver un ensemble  $S$  de sommets de cardinalité maximale tel que le sous-graphe induit par  $S$  ne possède pas d'arête (stable de  $G$ ).

- Soit  $\mathfrak{M}(G) = \{A \in \mathcal{S}_n : A_{ij} = 1 \text{ si } (i, j) \notin E \text{ ou } (i = j)\}$
- $\mathfrak{M}(G)$  est un **espace affine**



## 4.b.1. Le nombre de Lovász

### Le problème du STABLE

**Données.** Un  $G = (V, E)$  un graphe non orienté possédant  $n$  sommets.

**Question.** Trouver un ensemble  $S$  de sommets de cardinalité maximale tel que le sous-graphe induit par  $S$  ne possède pas d'arête (stable de  $G$ ).

- Soit  $\mathfrak{M}(G) = \{A \in S_n : A_{ij} = 1 \text{ si } (i, j) \notin E \text{ ou } (i = j)\}$
- $\mathfrak{M}(G)$  est un **espace affine**
- Pour tout  $[v_i, v_j] \in E$  on définit  $E^{ij}$  matrice de  $S_n$  telle que  $E_{ij}^{ij} = E_{ji}^{ij} = 1$  et sinon  $E_{kl}^{ij} = 0$

## 4.b.1. Le nombre de Lovász

### Le problème du STABLE

**Données.** Un  $G = (V, E)$  un graphe non orienté possédant  $n$  sommets.

**Question.** Trouver un ensemble  $S$  de sommets de cardinalité maximale tel que le sous-graphe induit par  $S$  ne possède pas d'arête (stable de  $G$ ).

- Soit  $\mathfrak{M}(G) = \{A \in S_n : A_{ij} = 1 \text{ si } (i, j) \notin E \text{ ou } (i = j)\}$
- $\mathfrak{M}(G)$  est un **espace affine**
- Pour tout  $[v_i, v_j] \in E$  on définit  $E^{ij}$  matrice de  $S_n$  telle que  $E_{ij}^{ij} = E_{ji}^{ij} = 1$  et sinon  $E_{kl}^{ij} = 0$
- **Repère** de l'espace affine  $\mathfrak{M}(G)$  : origine  $J_n$  (matrice de "1"), base  $\{\dots, E_{ij}, \dots\}$

## 4.b.1. Le nombre de Lovász


### Le problème du STABLE

**Données.** Un  $G = (V, E)$  un graphe non orienté possédant  $n$  sommets.

**Question.** Trouver un ensemble  $S$  de sommets de cardinalité maximale tel que le sous-graphe induit par  $S$  ne possède pas d'arête (stable de  $G$ ).


- Soit  $\mathfrak{M}(G) = \{A \in S_n : A_{ij} = 1 \text{ si } (i, j) \notin E \text{ ou } (i = j)\}$
- $\mathfrak{M}(G)$  est un **espace affine**
- Pour tout  $[v_i, v_j] \in E$  on définit  $E^{ij}$  matrice de  $S_n$  telle que  $E_{ij}^{ij} = E_{ji}^{ij} = 1$  et sinon  $E_{kl}^{ij} = 0$
- **Repère** de l'espace affine  $\mathfrak{M}(G)$  : origine  $J_n$  (matrice de "1"), base  $\{\dots, E^{ij}, \dots\}$
- $A \in \mathfrak{M}(G)$  si et seulement si  $A = J_n + \sum_{(i,j) \in E} x_{ij} E^{ij}$

Exemple :



$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & -5 & 1 & \mathbf{1} \\ \mathbf{1} & \mathbf{1} & 0 & 7 & \mathbf{1} \\ -5 & 0 & 1 & 6 & \mathbf{1} \\ 1 & 7 & 6 & 1 & -1 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & -1 & \mathbf{1} \end{bmatrix}$$


Exemple :



$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & -5 & 1 & \mathbf{1} \\ \mathbf{1} & \mathbf{1} & 0 & 7 & \mathbf{1} \\ -5 & 0 & 1 & 6 & \mathbf{1} \\ 1 & 7 & 6 & 1 & -1 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & -1 & \mathbf{1} \end{bmatrix}$$

- 1  $\exists$  stable de taille  $k$  dans  $G$  si et seulement si toute matrice  $A$  dans  $\mathfrak{M}(G)$  contient la sous-matrice  $J_k \in \mathcal{S}_k$ , matrice  $k \times k$  uniquement constituée de 1


Exemple :



$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & -5 & 1 & \mathbf{1} \\ \mathbf{1} & \mathbf{1} & 0 & 7 & \mathbf{1} \\ -5 & 0 & 1 & 6 & \mathbf{1} \\ 1 & 7 & 6 & 1 & -1 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & -1 & \mathbf{1} \end{bmatrix}$$

- 1  $\exists$  stable de taille  $k$  dans  $G$  si et seulement si toute matrice  $A$  dans  $\mathfrak{M}(G)$  contient la sous-matrice  $J_k \in \mathcal{S}_k$ , matrice  $k \times k$  uniquement constituée de 1
- 2 Les valeurs propres de  $J_k$  sont 0 et  $k$  ( $\text{rang}(J_k) = 1$ )


Exemple :



$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & -5 & 1 & \mathbf{1} \\ \mathbf{1} & \mathbf{1} & 0 & 7 & \mathbf{1} \\ -5 & 0 & 1 & 6 & \mathbf{1} \\ 1 & 7 & 6 & 1 & -1 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & -1 & \mathbf{1} \end{bmatrix}$$

- 1  $\exists$  stable de taille  $k$  dans  $G$  si et seulement si toute matrice  $A$  dans  $\mathfrak{M}(G)$  contient la sous-matrice  $J_k \in \mathcal{S}_k$ , matrice  $k \times k$  uniquement constituée de 1
- 2 Les valeurs propres de  $J_k$  sont 0 et  $k$  ( $\text{rang}(J_k) = 1$ )
- 3 Soit  $A \in \mathfrak{M}(G)$ , on a  $\lambda_{\max}(A) \geq \lambda_{\max}(J_k) = k$ .

Exemple :




$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & -5 & 1 & \mathbf{1} \\ \mathbf{1} & \mathbf{1} & 0 & 7 & \mathbf{1} \\ -5 & 0 & 1 & 6 & \mathbf{1} \\ 1 & 7 & 6 & 1 & -1 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & -1 & \mathbf{1} \end{bmatrix}$$

- 1  $\exists$  stable de taille  $k$  dans  $G$  si et seulement si toute matrice  $A$  dans  $\mathfrak{M}(G)$  contient la sous-matrice  $J_k \in \mathcal{S}_k$ , matrice  $k \times k$  uniquement constituée de 1
- 2 Les valeurs propres de  $J_k$  sont 0 et  $k$  ( $\text{rang}(J_k) = 1$ )
- 3 Soit  $A \in \mathfrak{M}(G)$ , on a  $\lambda_{\max}(A) \geq \lambda_{\max}(J_k) = k$ .
- 4 Donc pour tout  $A$  dans  $\mathfrak{M}(G)$   $\lambda_{\max}(A) \geq \alpha(G)$  (nombre de stabilité : taille d'un plus grand stable dans  $G$ )



Exemple :



$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & -5 & 1 & \mathbf{1} \\ \mathbf{1} & \mathbf{1} & 0 & 7 & \mathbf{1} \\ -5 & 0 & 1 & 6 & \mathbf{1} \\ 1 & 7 & 6 & 1 & -1 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & -1 & \mathbf{1} \end{bmatrix}$$

- 1  $\exists$  stable de taille  $k$  dans  $G$  si et seulement si toute matrice  $A$  dans  $\mathfrak{M}(G)$  contient la sous-matrice  $J_k \in \mathcal{S}_k$ , matrice  $k \times k$  uniquement constituée de 1
- 2 Les valeurs propres de  $J_k$  sont 0 et  $k$  ( $\text{rang}(J_k) = 1$ )
- 3 Soit  $A \in \mathfrak{M}(G)$ , on a  $\lambda_{\max}(A) \geq \lambda_{\max}(J_k) = k$ .
- 4 Donc pour tout  $A$  dans  $\mathfrak{M}(G)$   $\lambda_{\max}(A) \geq \alpha(G)$  (nombre de stabilité : taille d'un plus grand stable dans  $G$ )
- 5 Meilleure borne :  $\min_{A \in \mathfrak{M}(G)} \lambda_{\max}(A)$

# Formulation du problème comme PSD

On a  $\min \{ \lambda : \lambda I - A \succeq 0 \} = \lambda_{\max}(A)$

# Formulation du problème comme PSD

On a  $\min \{ \lambda : \lambda I - A \succeq 0 \} = \lambda_{\max}(A)$

- $\lambda I - A = \lambda I - MDM^T = M(\lambda I - D)M^T$  avec  $D = \begin{bmatrix} \lambda_1 & \dots & 0 \\ 0 & \lambda_j & 0 \\ 0 & \dots & \lambda_n \end{bmatrix}$

# Formulation du problème comme PSD

On a  $\min \{ \lambda : \lambda I - A \succeq 0 \} = \lambda_{\max}(A)$

- $\lambda I - A = \lambda I - MDM^T = M(\lambda I - D)M^T$  avec  $D = \begin{bmatrix} \lambda_1 & \dots & 0 \\ 0 & \lambda_i & 0 \\ 0 & \dots & \lambda_n \end{bmatrix}$
- $\lambda I - D \succeq 0 \Leftrightarrow \lambda \geq \lambda_{\max}(A)$

# Formulation du problème comme PSD

On a  $\min \{ \lambda : \lambda I - A \succeq 0 \} = \lambda_{\max}(A)$

- $\lambda I - A = \lambda I - MDM^T = M(\lambda I - D)M^T$  avec  $D = \begin{bmatrix} \lambda_1 & \dots & 0 \\ 0 & \lambda_i & 0 \\ 0 & \dots & \lambda_n \end{bmatrix}$
- $\lambda I - D \succeq 0 \Leftrightarrow \lambda \geq \lambda_{\max}(A)$

# Formulation du problème comme PSD

On a  $\min \{ \lambda : \lambda I - A \succeq 0 \} = \lambda_{\max}(A)$

- $\lambda I - A = \lambda I - MDM^T = M(\lambda I - D)M^T$  avec  $D = \begin{bmatrix} \lambda_1 & \dots & 0 \\ 0 & \lambda_i & 0 \\ 0 & \dots & \lambda_n \end{bmatrix}$
- $\lambda I - D \succeq 0 \Leftrightarrow \lambda \geq \lambda_{\max}(A)$

$\min_{A \in \mathfrak{M}(G)} \lambda_{\max}(A)$  est donc équivalent à :

$$\theta(G) \begin{cases} \min \lambda \\ \text{s.c : } \lambda I_n - \underbrace{\left( J_n + \sum_{(i,j) \in E} x_{ij} E^{ij} \right)}_{A \in \mathfrak{M}(G)} \succeq 0 \end{cases}$$

# Dual Semidéfini

$$\theta(G) \begin{cases} \min & \lambda \\ \text{s.c.} & \lambda I_n - \underbrace{\left( J_n + \sum_{(i,j) \in E} x_{ij} E^{ij} \right)}_{A \in \mathfrak{M}(G)} \succeq 0 \end{cases}$$

# Dual Semidéfini

$$\theta(G) \begin{cases} \min & \lambda \\ \text{s.c.} & \lambda I_n - \underbrace{\left( J_n + \sum_{(i,j) \in E} x_{ij} E^{ij} \right)}_{A \in \mathfrak{M}(G)} \succeq 0 \end{cases}$$

dual :



# Dual Semidéfini

$$\theta(G) \left\{ \begin{array}{l} \min \quad \lambda \\ \text{s.c. :} \quad \lambda I_n - \underbrace{\left( J_n + \sum_{(i,j) \in E} x_{ij} E^{ij} \right)}_{A \in \mathfrak{M}(G)} \succeq 0 \end{array} \right.$$

dual :

$$D\theta(G) \left\{ \begin{array}{l} \max \quad J_n \bullet Z = \sum_{i=1}^n \sum_{i=1}^n Z_{ij} \\ \text{s.c. :} \quad E^{ij} \bullet Z = Z_{ij} = 0 \quad \forall (i,j) \in E \\ \quad \quad I_n \bullet Z = \text{Trace}(Z) = 1 \\ \quad \quad Z \succeq 0 \end{array} \right.$$

# Dual Semidéfini

$$\theta(G) \begin{cases} \min & \lambda \\ \text{s.c. :} & \lambda I_n - \underbrace{\left( J_n + \sum_{(i,j) \in E} x_{ij} E^{ij} \right)}_{A \in \mathfrak{M}(G)} \succeq 0 \end{cases}$$

dual :

$$D\theta(G) \begin{cases} \max & J_n \bullet Z = \sum_{i=1}^n \sum_{i=1}^n Z_{ij} \\ \text{s.c. :} & E^{ij} \bullet Z = Z_{ij} = 0 \quad \forall (i,j) \in E \\ & I_n \bullet Z = \text{Trace}(Z) = 1 \\ & Z \succeq 0 \end{cases}$$

admet des points intérieurs :  $I_n/n$  est strictement admissible. Donc **pas de saut de dualité**

# Application dans les Graphes Parfaits

- Dans un graphe **parfait**  $G$ , le nombre de stabilité (taille d'un plus grand stable) est égal au nombre chromatique du complémentaire de  $G$  par les arêtes :  $\alpha(G) = \chi(\bar{G})$

# Application dans les Graphes Parfaits

- Dans un graphe **parfait**  $G$ , le nombre de stabilité (taille d'un plus grand stable) est égal au nombre chromatique du complémentaire de  $G$  par les arêtes :  $\alpha(G) = \chi(\bar{G})$
- $\chi(\bar{G})$  : nombre minimal de couleurs pour colorier les sommets de  $\bar{G}$  (deux sommets adjacents n'ont pas la même couleur)

# Application dans les Graphes Parfaits

- Dans un graphe **parfait**  $G$ , le nombre de stabilité (taille d'un plus grand stable) est égal au nombre chromatique du complémentaire de  $G$  par les arêtes :  $\alpha(G) = \chi(\bar{G})$
- $\chi(\bar{G})$  : nombre minimal de couleurs pour colorier les sommets de  $\bar{G}$  (deux sommets adjacents n'ont pas la même couleur)

## Théorème

*Pour tout graphe  $G$  on a  $\alpha(G) \leq \theta(G) \leq \chi(\bar{G})$*

# Application dans les Graphes Parfaits

- Dans un graphe **parfait**  $G$ , le nombre de stabilité (taille d'un plus grand stable) est égal au nombre chromatique du complémentaire de  $G$  par les arêtes :  $\alpha(G) = \chi(\bar{G})$
- $\chi(\bar{G})$  : nombre minimal de couleurs pour colorier les sommets de  $\bar{G}$  (deux sommets adjacents n'ont pas la même couleur)

## Théorème

*Pour tout graphe  $G$  on a  $\alpha(G) \leq \theta(G) \leq \chi(\bar{G})$*

- On a déjà vu que  $\alpha(G) \leq \theta(G) = D\theta(G)$

# Application dans les Graphes Parfaits

- Dans un graphe **parfait**  $G$ , le nombre de stabilité (taille d'un plus grand stable) est égal au nombre chromatique du complémentaire de  $G$  par les arêtes :  $\alpha(G) = \chi(\bar{G})$
- $\chi(\bar{G})$  : nombre minimal de couleurs pour colorier les sommets de  $\bar{G}$  (deux sommets adjacents n'ont pas la même couleur)

## Théorème

*Pour tout graphe  $G$  on a  $\alpha(G) \leq \theta(G) \leq \chi(\bar{G})$*

- On a déjà vu que  $\alpha(G) \leq \theta(G) = D\theta(G)$
- Donc si on montre que  $D\theta(G) \leq \chi(\bar{G})$ , on obtiendra  $\alpha(G)$  dans les graphes parfaits !

# Application dans les Graphes Parfaits

- Dans un graphe **parfait**  $G$ , le nombre de stabilité (taille d'un plus grand stable) est égal au nombre chromatique du complémentaire de  $G$  par les arêtes :  $\alpha(G) = \chi(\bar{G})$
- $\chi(\bar{G})$  : nombre minimal de couleurs pour colorier les sommets de  $\bar{G}$  (deux sommets adjacents n'ont pas la même couleur)

## Théorème

*Pour tout graphe  $G$  on a  $\alpha(G) \leq \theta(G) \leq \chi(\bar{G})$*

- On a déjà vu que  $\alpha(G) \leq \theta(G) = D\theta(G)$
- Donc si on montre que  $D\theta(G) \leq \chi(\bar{G})$ , on obtiendra  $\alpha(G)$  dans les graphes parfaits !
- Et même  $\chi(G)$  car le complément d'un graphe parfait est parfait ("weak perfect graph conjecture", Lovász)



$$D\theta(G) \left\{ \begin{array}{l} \max \quad J_n \bullet Z = \sum_{i=1}^n \sum_{j=1}^n Z_{ij} \\ \text{s.c. :} \quad Z_{ij} = 0 \\ \quad \quad \quad I_n \bullet Z = \text{Trace}(Z) = 1 \\ \quad \quad \quad Z \succeq 0 \end{array} \right. \quad \forall (i, j) \in E$$

- Soit une partition  $C_1, \dots, C_k$  de  $G$  en  $k$  cliques (i.e. une coloration de  $\bar{G}$ ), et  $Z$  admissible pour  $D\theta(G)$

$$D\theta(G) \begin{cases} \max & J_n \bullet Z = \sum_{i=1}^n \sum_{j=1}^n Z_{ij} \\ \text{s.c. :} & Z_{ij} = 0 \quad \forall (i,j) \in E \\ & I_n \bullet Z = \text{Trace}(Z) = 1 \\ & Z \succeq 0 \end{cases}$$

- Soit une partition  $C_1, \dots, C_k$  de  $G$  en  $k$  cliques (i.e. une coloration de  $\bar{G}$ ), et  $Z$  admissible pour  $D\theta(G)$
- Soit  $v^i$  tel que  $v_j^i = 1 \Leftrightarrow$  le sommet  $j$  est dans  $C_i$   
donc  $v_j^k = 0 \forall k \neq i$

$$D\theta(G) \begin{cases} \max & J_n \bullet Z = \sum_{i=1}^n \sum_{j=1}^n Z_{ij} \\ \text{s.c. :} & Z_{ij} = 0 \quad \forall (i,j) \in E \\ & I_n \bullet Z = \text{Trace}(Z) = 1 \\ & Z \succeq 0 \end{cases}$$

- Soit une partition  $C_1, \dots, C_k$  de  $G$  en  $k$  cliques (i.e. une coloration de  $\bar{G}$ ), et  $Z$  admissible pour  $D\theta(G)$
- Soit  $v^i$  tel que  $v_j^i = 1 \Leftrightarrow$  le sommet  $j$  est dans  $C_i$   
donc  $v_j^k = 0 \forall k \neq i$
- $Z \succeq 0$  donc  $\sum_{i=1}^k (kv^i - e_n)^T Z (kv^i - e_n) \geq 0$ , où  $e_n = (1, \dots, 1)^T$

$$D\theta(G) \begin{cases} \max & J_n \bullet Z = \sum_{i=1}^n \sum_{i=1}^n Z_{ij} \\ \text{s.c. :} & Z_{ij} = 0 \quad \forall (i,j) \in E \\ & I_n \bullet Z = \text{Trace}(Z) = 1 \\ & Z \succeq 0 \end{cases}$$

- Soit une partition  $C_1, \dots, C_k$  de  $G$  en  $k$  cliques (i.e. une coloration de  $\bar{G}$ ), et  $Z$  admissible pour  $D\theta(G)$
- Soit  $v^i$  tel que  $v_j^i = 1 \Leftrightarrow$  le sommet  $j$  est dans  $C_i$   
donc  $v_j^k = 0 \forall k \neq i$
- $Z \succeq 0$  donc  $\sum_{i=1}^k (kv^i - e_n)^T Z (kv^i - e_n) \geq 0$ , où  $e_n = (1, \dots, 1)^T$
- $0 \leq k \left( \sum_{i=1}^k v^i (v^i)^T \right) \bullet Z - 2 \left( \sum_{i=1}^k v^i \right)^T Z e_n + J_n \bullet Z$

$$D\theta(G) \begin{cases} \max & J_n \bullet Z = \sum_{i=1}^n \sum_{i=1}^n Z_{ij} \\ \text{s.c. :} & Z_{ij} = 0 \\ & I_n \bullet Z = \text{Trace}(Z) = 1 \\ & Z \succeq 0 \end{cases} \quad \forall (i, j) \in E$$

- Soit une partition  $C_1, \dots, C_k$  de  $G$  en  $k$  cliques (i.e. une coloration de  $\bar{G}$ ), et  $Z$  admissible pour  $D\theta(G)$
- Soit  $v^i$  tel que  $v_j^i = 1 \Leftrightarrow$  le sommet  $j$  est dans  $C_i$   
donc  $v_j^k = 0 \forall k \neq i$
- $Z \succeq 0$  donc  $\sum_{i=1}^k (kv^i - e_n)^T Z (kv^i - e_n) \geq 0$ , où  $e_n = (1, \dots, 1)^T$
- $0 \leq k \left( \sum_{i=1}^k v^i (v^i)^T \right) \bullet Z - 2 \left( \sum_{i=1}^k v^i \right)^T Z e_n + J_n \bullet Z$
- Or  $\left( \sum_{i=1}^k v^i \right)^T Z e_n = e_n e_n^T \bullet Z$  (partition)

$$D\theta(G) \begin{cases} \max & J_n \bullet Z = \sum_{i=1}^n \sum_{j=1}^n Z_{ij} \\ \text{s.c. :} & Z_{ij} = 0 \quad \forall (i,j) \in E \\ & I_n \bullet Z = \text{Trace}(Z) = 1 \\ & Z \succeq 0 \end{cases}$$

- Soit une partition  $C_1, \dots, C_k$  de  $G$  en  $k$  cliques (i.e. une coloration de  $\bar{G}$ ), et  $Z$  admissible pour  $D\theta(G)$
- Soit  $v^i$  tel que  $v_j^i = 1 \Leftrightarrow$  le sommet  $j$  est dans  $C_i$   
donc  $v_j^k = 0 \forall k \neq i$
- $Z \succeq 0$  donc  $\sum_{i=1}^k (kv^i - e_n)^T Z (kv^i - e_n) \geq 0$ , où  $e_n = (1, \dots, 1)^T$
- $0 \leq k \left( \sum_{i=1}^k v^i (v^i)^T \right) \bullet Z - 2 \left( \sum_{i=1}^k v^i \right)^T Z e_n + J_n \bullet Z$
- Or  $\left( \sum_{i=1}^k v^i \right)^T Z e_n = e_n e_n^T \bullet Z$  (partition)
- Donc  $0 \leq k I_n \bullet Z - J_n \bullet Z$  donc  $J_n \bullet Z \leq \chi(\bar{G})$

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

**4. Approche par Programmation Semidéfinie**

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

# Problème Quadratique 0-1 sans autre contrainte

$$(QP)_{\{0,1\}} \left\{ \begin{array}{l} \max f(x) = \frac{1}{2} \sum_{i=1}^n \sum_{j \neq i} C_{ij} x_i x_j + \sum_{i=1}^n b_i x_i \\ \quad = \frac{1}{2} \mathbf{C} \bullet \mathbf{x} \mathbf{x}^T + \mathbf{b}^T \mathbf{x} \\ \text{s.c. } x_i \in \{0, 1\} ; i = 1, \dots, n \end{array} \right.$$



# Problème Quadratique 0-1 sans autre contrainte

$$(QP)_{\{0,1\}} \left\{ \begin{array}{l} \max f(x) = \frac{1}{2} \sum_{i=1}^n \sum_{j \neq i} C_{ij} x_i x_j + \sum_{i=1}^n b_i x_i \\ \quad = \frac{1}{2} C \bullet x x^T + b^T x \\ \text{s.c. } x_i \in \{0, 1\} ; i = 1, \dots, n \end{array} \right.$$

**Relaxation "Classique" par programmation linéaire :**

$$(LP)_{\{0,1\}} \left\{ \begin{array}{l} \max \frac{1}{2} C \bullet X + b^T x \\ \text{s.c. } 0 \leq x_i \leq 1 \quad i \in \{1, \dots, n\} \\ \quad 0 \leq X_{ij} \leq x_i \quad i \neq j \in \{1, \dots, n\} \\ \quad 0 \leq X_{ij} \leq x_j \quad i \neq j \in \{1, \dots, n\} \\ \quad x_i + x_j \leq 1 + X_{ij} \quad i \neq j \in \{1, \dots, n\} \end{array} \right.$$

## 4.b.2. Relaxation SDP en $\{0, 1\}$

**Rappel.**  $(X, x) \in \mathcal{S}_n \times \mathbb{R}^n$

$$\text{on a } \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0 \Leftrightarrow X - xx^T \succeq 0.$$

### RELAXATION

$X = xx^T \implies$	$X \succeq xx^T$
$x_i \in \{0, 1\} \implies$	$x_i \text{ réel}$
	$\mathbf{d}(X) = x$

$$\begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0 \Rightarrow \det \begin{bmatrix} 1 & x_i \\ x_i & x_i \end{bmatrix} \geq 0 \quad \forall i$$

$$\text{i.e. } 1 \geq x_i \geq x_i^2 \geq 0$$

$$(SDP)_{QP\{0,1\}} \left\{ \begin{array}{l} \max \frac{1}{2} C \bullet X + b^T x \\ \text{s.c. } \mathbf{d}(X) = x \\ \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0 \end{array} \right.$$

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

**4. Approche par Programmation Semidéfinie**

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

## 4.b.3. Relaxation SDP en $\{-1, 1\}$

### Démarche géométrique

$$x_i = \frac{1+y_i}{2} \text{ et } y_i = 2x_i - 1 \quad (i \in \{1, \dots, n, \})$$

$$(QP)_{\{-1,1\}} \left\{ \begin{array}{l} \text{Max } f(y) = \frac{1}{8} \sum_{i=1}^n \sum_{j \neq i} C_{ij} (1 + y_i) (1 + y_j) \\ \quad + \frac{1}{2} \sum_{i=1}^n b_i (1 + y_i) \\ = \frac{1}{8} \left[ C \bullet yy^T + \sum_{i=1}^n \left( 4b_i + 2 \sum_{j \neq i} C_{ij} \right) y_i \right] \\ \quad + \left( \frac{1}{4} C_{tot} + \frac{1}{2} \sum_{i=1}^n b_i \right) \\ \text{s.c. } y_i \in \{-1, 1\} ; i = 1, \dots, n \end{array} \right.$$

### Relaxation sur la dimension

#### RELAXATION

$y_i \in \{-1, 1\} \implies$	$v_i \in S^n$
$y_i y_j \implies$	$v_i^T v_j$
$y_i$	$v_i^T v_0$

## Relaxation SDP en $\{-1, 1\}$

$$(P)_{QP\{-1,1\}} \begin{cases} \max F(v_0, \dots, v_n) = \frac{1}{8} \sum_{i=1}^n \sum_{j \neq i} C_{ij} v_i^T v_j \\ \quad + \sum_{i=1}^n \left( 4b_i + 2 \sum_{j \neq i} C_{ij} \right) v_i^T v_0 \\ \quad + \left( \frac{1}{4} C_{tot} + \frac{1}{2} \sum_{i=1}^n b_i \right) \\ \text{s.c. : } v_i \in \mathbf{S}^n \quad i = 0, \dots, n \end{cases} \quad (1)$$

$Y = VV^T$  avec  $Y_{ii} = 1 ; i = 0, \dots, n$

$\Leftrightarrow v_i \in \mathbf{S}^n \quad i = 0, \dots, n$  (Cholesky)

$$\Leftrightarrow (SDP)_{QP\{-1,1\}} \begin{cases} \text{Max } \frac{1}{8} C' \bullet Y + \left( \frac{1}{4} C_{tot} + \frac{1}{2} \sum_{i=1}^n b_i \right) \\ \text{s.c. } \mathbf{d}(Y) = \mathbf{e}_{n+1} \\ Y \in \mathbf{S}_{n+1}^+ \end{cases}$$

$$\text{où } C' = \begin{bmatrix} 0 & b'^T \\ b' & C \end{bmatrix}$$

$$\text{et } b' = 2b + \left( \sum_{j=1}^n C_{1j}, \dots, \sum_{j=1}^n C_{ij}, \dots, \sum_{j=1}^n C_{nj} \right)$$

**Question** : les deux SDPs obtenus sont-ils équivalents ?

# Equivalence des relaxations SDP

$Q$  inversible,  $M \in S_n$  on pose  $\phi(M) = QMQ^T$ .  $\phi$  laisse stable  $S_n^+$ .

**Changement de variable**  $W = QXQ^T$

$$(SDP) \begin{cases} \text{Max } C \bullet X \\ \text{s.c. } A_i \bullet X = (\text{ou } \leq) b_i; i = 1, \dots, k \\ X \succeq 0 \end{cases}$$

$\tilde{C} = (Q^{-1})^T C Q^{-1}$ , et  $\tilde{A}_i = (Q^{-1})^T A_i Q^{-1}$  pour  $i \in \{1, \dots, k\}$

$$(SDP)_Q \begin{cases} \max \tilde{C} \bullet W \\ \text{s.c. } \tilde{A}_i \bullet W = (\text{ou } \leq) b_i; i = 1, \dots, k \\ W \succeq 0 \end{cases}$$

**Lemme.**  $X$  est une solution admissible de  $(SDP)$  si et seulement si  $W = QXQ^T$  est une solution admissible de  $(SDP)_Q$ . De plus, on a  $C \bullet X = \tilde{C} \bullet W$

## Application aux cas $\{0, 1\}$ et $\{-1, 1\}$

Initialement :  $x = \frac{1}{2}(y + e_n)$

$$\text{i.e. } \begin{pmatrix} 1 \\ x \end{pmatrix} = Q \begin{pmatrix} 1 \\ y \end{pmatrix} \text{ avec } Q = \begin{bmatrix} 1 & 0 \\ \frac{1}{2}e & \frac{1}{2}I_n \end{bmatrix}$$

$$\text{On a } Q^{-1} = \begin{bmatrix} 1 & 0 \\ -e & 2I_n \end{bmatrix}$$

SDP $\{-1, 1\}$	SDP $\{0, 1\}$
$Y_{ii} = E_i \bullet Y = 1 \forall i$	$(Q^{-1})^T E_i Q^{-1} \Rightarrow X_{ii} = X_{0i}$
$Y \succeq 0$	$X \succeq 0$

$$(Q^{-1})^T E_i Q^{-1} = \begin{bmatrix} 1 & -e_n \\ 0 & 2I_n \end{bmatrix} E_i \begin{bmatrix} 1 & 0 \\ -e_n & 2I_n \end{bmatrix}$$

implique  $X_{00} - 4X_{0i} + 4X_{ii} = 1$

$$\text{i.e. } X_{ii} = X_{0i} \forall i \in \{1, \dots, n\} \quad (X_{00} = 1)$$

## Calcul de la fonction Objectif en $\{0, 1\}$

En  $\{-1, 1\}$  on a  $f(Y) = \left(\frac{1}{4}C_{tot} + \frac{1}{2} \sum_{i=1}^n b_i\right) + \frac{1}{8} C' \bullet Y$

$$\text{où } C' = \begin{bmatrix} 0 & b'^T \\ b' & C \end{bmatrix}$$

$$\text{et } b' = 2b + \left(\sum_{j=1}^n C_{1j}, \dots, \sum_{j=1}^n C_{ij}, \dots, \sum_{j=1}^n C_{nj}\right)$$

$$\text{En } \{0, 1\} : (Q^{-1})^T C' Q^{-1} = \begin{bmatrix} -4 \sum_{i=1}^n b_i - 2C_{tot} & 4b^T \\ 4b & 4C \end{bmatrix}$$

$$\begin{aligned} g(X) &= \frac{1}{2} \sum_{i=1}^n b_i + \frac{1}{4} C_{tot} + \frac{1}{8} \phi^{-1}(C') \bullet X \\ &= \frac{1}{2} \sum_{i=1}^n b_i + \frac{1}{4} C_{tot} \\ &\quad + \frac{1}{8} \left( -4 \sum_{i=1}^n b_i - 2C_{tot} + 4 \sum_{i=1}^n \sum_{j \neq i} C_{ij} X_{ij} + 8b^T x \right) \\ &= \frac{1}{2} C \bullet X + b^T x \end{aligned}$$



# Améliorations semidéfinies de l'approche par PL

$$(SDP_2)_{\{0,1\}} \left\{ \begin{array}{l} \text{Max } \frac{1}{2} C \bullet X + b^T x \\ \text{s.c. } \mathbf{d}(X) = x \\ \begin{bmatrix} 1 & x \\ x^T & X \end{bmatrix} \succeq 0 \\ 0 \leq X_{ij} \quad i \neq j \in \{1, \dots, n\} \\ X_{ij} \leq X_{ji} \quad i \neq j \in \{1, \dots, n\} \\ X_{ij} \leq X_{jj} \quad i \neq j \in \{1, \dots, n\} \\ X_{ii} + X_{jj} \leq 1 + X_{ij} \quad i \neq j \in \{1, \dots, n\} \end{array} \right.$$

Est équivalent à

$$(SDP_2)_{\{-1,1\}} \left\{ \begin{array}{l} \text{Max } \frac{1}{8} C' \bullet Y + \left( \frac{1}{4} C_{tot} + \frac{1}{2} \sum_{i=1}^n b_i \right) \\ \text{s.c. } Y_{0i} + Y_{0j} + Y_{ij} \geq -1 \quad i \neq j \in \{1, \dots, n\} \\ Y_{ij} - Y_{i0} - Y_{j0} \geq -1 \quad i \neq j \in \{1, \dots, n\} \\ Y_{i0} - Y_{j0} - Y_{ij} \geq -1 \quad i \neq j \in \{1, \dots, n\} \\ -Y_{i0} + Y_{j0} - Y_{ij} \geq -1 \quad i \neq j \in \{1, \dots, n\} \\ \mathbf{d}(Y) = \mathbf{e}_{n+1} \\ Y \in \mathbf{S}_{n+1}^+ \end{array} \right.$$

# Application au problème du stable

Modèle par programme linéaire en variables 0-1 :

$$\left\{ \begin{array}{l} \max \quad \sum_{i=1}^n x_i \\ \text{s.c. :} \quad (0 \leq) x_i + x_j \leq 1 \quad \forall (i, j) \in E \\ \quad \quad x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $(x_i + x_j - 1)(x_i + x_j) \leq 0 \quad \forall (i, j) \in E$

# Application au problème du stable

Modèle par programme linéaire en variables 0-1 :

$$\left\{ \begin{array}{l} \max \quad \sum_{i=1}^n x_i \\ \text{s.c. :} \quad (0 \leq) x_i + x_j \leq 1 \quad \forall (i, j) \in E \\ \quad \quad \quad x_i \in \{0, 1\} \quad \quad \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $(x_i + x_j - 1)(x_i + x_j) \leq 0 \quad \forall (i, j) \in E$
- Donc  $0 \leq x_i x_j \leq 0 \Rightarrow x_{ij} = 0 \quad \forall (i, j) \in E$

# Application au problème du stable

Modèle par programme linéaire en variables 0-1 :

$$\left\{ \begin{array}{l} \max \quad \sum_{i=1}^n x_i \\ \text{s.c. :} \quad (0 \leq) x_i + x_j \leq 1 \quad \forall (i, j) \in E \\ \quad \quad \quad x_i \in \{0, 1\} \quad \quad \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $(x_i + x_j - 1)(x_i + x_j) \leq 0 \quad \forall (i, j) \in E$
- Donc  $0 \leq x_i x_j \leq 0 \Rightarrow x_{ij} = 0 \quad \forall (i, j) \in E$

# Application au problème du stable

Modèle par programme linéaire en variables 0-1 :

$$\left\{ \begin{array}{ll} \max & \sum_{i=1}^n x_i \\ \text{s.c. :} & (0 \leq) x_i + x_j \leq 1 \quad \forall (i, j) \in E \\ & x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $(x_i + x_j - 1)(x_i + x_j) \leq 0 \quad \forall (i, j) \in E$
- Donc  $0 \leq x_i x_j \leq 0 \Rightarrow x_{ij} = 0 \quad \forall (i, j) \in E$

Autre formulation semidéfinie du nombre de Lovász :

$$\theta_G = \left\{ \begin{array}{ll} \max & \sum_{i=1}^n x_i \\ \text{s.c. :} & X_{ij} = 0 \quad \forall (i, j) \in E \\ & X_{ii} = x_i \quad i = 1, \dots, n \\ & X - xx^T \succeq 0 \end{array} \right.$$

# Etude de cas

Problème du sac-à-dos (knapsack) quadratique (déjà étudié par l'approche linéaire)

$$(KQP) \quad \begin{cases} \min & x^T Q x + c^T x \\ \text{s.c.} & a^T x \leq b \\ & x \in \{0, 1\}^n \end{cases}$$

## 1 Relaxation semidéfinie "basique"

# Etude de cas

Problème du sac-à-dos (knapsack) quadratique (déjà étudié par l'approche linéaire)

$$(KQP) \begin{cases} \min & x^T Qx + c^T x \\ \text{s.c.} & a^T x \leq b \\ & x \in \{0, 1\}^n \end{cases}$$

- 1 Relaxation semidéfinie "basique"
- 2 Premier traitement de la contrainte d'inégalité

# Etude de cas

Problème du sac-à-dos (knapsack) quadratique (déjà étudié par l'approche linéaire)

$$(KQP) \begin{cases} \min & x^T Q x + c^T x \\ \text{s.c.} & a^T x \leq b \\ & x \in \{0, 1\}^n \end{cases}$$

- 1 Relaxation semidéfinie "basique"
- 2 Premier traitement de la contrainte d'inégalité
- 3 Deuxième traitement de la contrainte d'inégalité



# Etude de cas

Problème du sac-à-dos (knapsack) quadratique (déjà étudié par l'approche linéaire)

$$(KQP) \begin{cases} \min & x^T Q x + c^T x \\ \text{s.c.} & a^T x \leq b \\ & x \in \{0, 1\}^n \end{cases}$$

- 1 Relaxation semidéfinie "basique"
- 2 Premier traitement de la contrainte d'inégalité
- 3 Deuxième traitement de la contrainte d'inégalité
- 4 Comparaison des approches

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

**4. Approche par Programmation Semidéfinie**

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

# Lagrangien total d'un Programme Quadratique

Programme Quadratique quelconque :

$$(Q) \begin{cases} \min_{x \in \mathbb{R}^n} & x^T A_0 x + b^T x \\ \text{s.c.} & x^T A_i x + c_i^T x - d_i \leq 0 \quad \forall i \in \{1, \dots, m\} \end{cases}$$

# Lagrangien total d'un Programme Quadratique

Programme Quadratique quelconque :

$$(Q) \begin{cases} \min_{x \in \mathbb{R}^n} & x^T A_0 x + b^T x \\ \text{s.c.} & x^T A_i x + c_i^T x - d_i \leq 0 \quad \forall i \in \{1, \dots, m\} \end{cases}$$

Son programme dual est (Lagrangien **total**) :

$$(DT) \sup_{\lambda \geq 0} \Theta(\lambda) = \inf_{x \in \mathbb{R}^n} x^T A(\lambda) x + b(\lambda)^T x - \lambda^T d$$

où  $A(\lambda) = A_0 + \sum_{i=1}^m \lambda_i A_i$  et  $b(\lambda) = b + \sum_{i=1}^m \lambda_i c_i$

# Lagrangien total d'un Programme Quadratique

Programme Quadratique quelconque :

$$(Q) \begin{cases} \min_{x \in \mathbb{R}^n} & x^T A_0 x + b^T x \\ \text{s.c.} & x^T A_i x + c_i^T x - d_i \leq 0 \quad \forall i \in \{1, \dots, m\} \end{cases}$$

Son programme dual est (Lagrangien **total**) :

$$(DT) \sup_{\lambda \geq 0} \Theta(\lambda) = \inf_{x \in \mathbb{R}^n} x^T A(\lambda) x + b(\lambda)^T x - \lambda^T d$$

où  $A(\lambda) = A_0 + \sum_{i=1}^m \lambda_i A_i$  et  $b(\lambda) = b + \sum_{i=1}^m \lambda_i c_i$

## Proposition

$\Theta(\lambda)$  est finie si et seulement si  $A(\lambda) \succcurlyeq 0$  et  $\exists x_\lambda$  tel que  $2A(\lambda)x_\lambda + b(\lambda) = 0$  (point critique)

$$(DT) \sup_{\lambda \geq 0} \Theta(\lambda) = \inf_{x \in \mathbb{R}^n} x^T A(\lambda)x + b(\lambda)^T x - \lambda^T d$$

## Proposition

(DT) peut se formuler comme le programme semidéfini suivant :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & F(r, \lambda) = \begin{bmatrix} -r & \frac{1}{2}b(\lambda)^T \\ \frac{1}{2}b(\lambda) & A(\lambda) \end{bmatrix} \preceq 0 \end{cases}$$

$$(DT) \sup_{\lambda \geq 0} \Theta(\lambda) = \inf_{x \in \mathbb{R}^n} x^T A(\lambda)x + b(\lambda)^T x - \lambda^T d$$

## Proposition

(DT) peut se formuler comme le programme semidéfini suivant :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & F(r, \lambda) = \begin{bmatrix} -r & \frac{1}{2}b(\lambda)^T \\ \frac{1}{2}b(\lambda) & A(\lambda) \end{bmatrix} \succcurlyeq 0 \end{cases}$$

- $(r, \lambda)$  est admissible de (SD)  $\Leftrightarrow \forall (\alpha, y) \in \mathbb{R} \times \mathbb{R}^n$   
 $q(\alpha, y) = -\alpha^2 r + \alpha b(\lambda)^T y + y^T A(\lambda)y$  est positive

$$(DT) \sup_{\lambda \geq 0} \Theta(\lambda) = \inf_{x \in \mathfrak{R}^n} x^T A(\lambda)x + b(\lambda)^T x - \lambda^T d$$

## Proposition

(DT) peut se formuler comme le programme semidéfini suivant :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & F(r, \lambda) = \begin{bmatrix} -r & \frac{1}{2}b(\lambda)^T \\ \frac{1}{2}b(\lambda) & A(\lambda) \end{bmatrix} \succcurlyeq 0 \end{cases}$$

- $(r, \lambda)$  est admissible de (SD)  $\Leftrightarrow \forall (\alpha, y) \in \mathfrak{R} \times \mathfrak{R}^n$   
 $q(\alpha, y) = -\alpha^2 r + \alpha b(\lambda)^T y + y^T A(\lambda)y$  est positive
- $\alpha = 0 : A(\lambda) \succcurlyeq 0$



$$(DT) \sup_{\lambda \geq 0} \Theta(\lambda) = \inf_{x \in \mathbb{R}^n} x^T A(\lambda)x + b(\lambda)^T x - \lambda^T d$$

## Proposition

(DT) peut se formuler comme le programme semidéfini suivant :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & F(r, \lambda) = \begin{bmatrix} -r & \frac{1}{2} b(\lambda)^T \\ \frac{1}{2} b(\lambda) & A(\lambda) \end{bmatrix} \succcurlyeq 0 \end{cases}$$

- $(r, \lambda)$  est admissible de (SD)  $\Leftrightarrow \forall (\alpha, y) \in \mathbb{R} \times \mathbb{R}^n$   
 $q(\alpha, y) = -\alpha^2 r + \alpha b(\lambda)^T y + y^T A(\lambda) y$  est positive
- $\alpha = 0 : A(\lambda) \succcurlyeq 0$
- $\alpha \neq 0 : q(1, x) = -r + b(\lambda)^T x + x^T A(\lambda) x \geq 0$  pour tout  $x$  dans  $\mathbb{R}^n$ .  
 Donc  $r - \lambda^T d \leq x^T A(\lambda) x + b(\lambda)^T x - \lambda^T d$

# Bidualiser $\Leftrightarrow$ convexifier en Programme Semidéfini

Le dual semidéfini de :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & \begin{bmatrix} -r & \frac{b^T + \sum_{i=1}^m \lambda_i c_i^T}{2} \\ \frac{b + \sum_{i=1}^m \lambda_i c_i}{2} & A_0 + \sum_{i=1}^m \lambda_i A_i \end{bmatrix} \succcurlyeq 0 \end{cases}$$

# Bidualiser $\Leftrightarrow$ convexifier en Programme Semidéfini

Le dual semidéfini de :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & \begin{bmatrix} -r & \frac{b^T + \sum_{i=1}^m \lambda_i c_i^T}{2} \\ \frac{b + \sum_{i=1}^m \lambda_i c_i}{2} & A_0 + \sum_{i=1}^m \lambda_i A_i \end{bmatrix} \succcurlyeq 0 \end{cases}$$

est :

$$(SDP_Q) \begin{cases} \min & \begin{bmatrix} 0 & \frac{b^T}{2} \\ \frac{b}{2} & A_0 \end{bmatrix} \bullet \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \\ \text{s.c.} & A_i \bullet X + c_i^T x - d_i \leq 0 \quad \forall i \in \{1, \dots, m\} \\ & \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succcurlyeq 0 \end{cases}$$

# Bidualiser $\Leftrightarrow$ convexifier en Programme Semidéfini

Le dual semidéfini de :

$$(SD) \begin{cases} \sup_{\lambda \geq 0} & r - \lambda^T d \\ \text{s.c.} & \begin{bmatrix} -r & \frac{b^T + \sum_{i=1}^m \lambda_i c_i^T}{2} \\ \frac{b + \sum_{i=1}^m \lambda_i c_i}{2} & A_0 + \sum_{i=1}^m \lambda_i A_i \end{bmatrix} \succcurlyeq 0 \end{cases}$$

est :

$$(SDP_Q) \begin{cases} \min & \begin{bmatrix} 0 & \frac{b^T}{2} \\ \frac{b}{2} & A_0 \end{bmatrix} \bullet \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \\ \text{s.c.} & A_i \bullet X + c_i^T x - d_i \leq 0 \quad \forall i \in \{1, \dots, m\} \\ & \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succcurlyeq 0 \end{cases}$$

On retrouve la relaxation semidéfinie issue du modèle  $\{0,1\}$

# Lagrangien Partiel

Supposons que notre problème Quadratique contient des contraintes **linéaires** :

$$(P) \quad \left\{ \begin{array}{l} \min_{x \in \mathbb{R}^n} \quad x^T Q x + c^T x \\ \text{s.c.} \quad \quad \quad x^T B_j x + d_j^T x = (\text{ou } \leq) e_j \quad i \in I = \{1, \dots, m\} \\ \quad \quad \quad \quad \quad Ax = b \end{array} \right.$$

# Lagrangien Partiel

Supposons que notre problème Quadratique contient des contraintes **linéaires** :

$$(P) \quad \left\{ \begin{array}{l} \min_{x \in \mathbb{R}^n} \quad x^T Q x + c^T x \\ \text{s.c.} \quad \quad \quad x^T B_j x + d_j^T x = (\text{ou } \leq) e_j \quad i \in I = \{1, \dots, m\} \\ \quad \quad \quad \quad \quad Ax = b \end{array} \right.$$

# Lagrangien Partiel

Supposons que notre problème Quadratique contient des contraintes **linéaires** :

$$(P) \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x + c^T x \\ \text{s.c.} & x^T B_j x + d_j^T x = (\text{ou } \leq) e_j \quad i \in I = \{1, \dots, m\} \\ & Ax = b \end{cases}$$

- On **ne relâche pas** les contraintes linéaires :

$$\mathcal{L}_{DP}(x, \mu) = x^T \left( Q + \sum_{i \in I} \mu_i B_i \right) x + \left( c + \sum_{i \in I} \mu_i d_i \right)^T x - \mu^T e$$

# Lagrangien Partiel

Supposons que notre problème Quadratique contient des contraintes **linéaires** :

$$(P) \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x + c^T x \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ & Ax = b \end{cases}$$

- On **ne relâche pas** les contraintes linéaires :

$$\mathcal{L}_{DP}(x, \mu) = x^T (Q + \sum_{i \in I} \mu_i B_i) x + (c + \sum_{i \in I} \mu_i d_i)^T x - \mu^T e$$

- Rappel : Dans la relaxation (totale) précédente :

$$\mathcal{L}_{DT}(x, \mu, \lambda) = \mathcal{L}_{DP}(x, \mu) + \lambda^T (Ax - b)$$



# Lagrangien Partiel

Supposons que notre problème Quadratique contient des contraintes **linéaires** :

$$(P) \quad \begin{cases} \min_{x \in \mathbb{R}^n} & x^T Q x + c^T x \\ \text{s.c.} & x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ & Ax = b \end{cases}$$

- On **ne relâche pas** les contraintes linéaires :

$$\mathcal{L}_{DP}(x, \mu) = x^T (Q + \sum_{i \in I} \mu_i B_i) x + (c + \sum_{i \in I} \mu_i d_i)^T x - \mu^T e$$

- Rappel : Dans la relaxation (totale) précédente :

$$\mathcal{L}_{DT}(x, \mu, \lambda) = \mathcal{L}_{DP}(x, \mu) + \lambda^T (Ax - b)$$

## Proposition

$$(DT) \sup_{\mu, \lambda} \inf_x \mathcal{L}_{DT}(x, \mu, \lambda) \leq (DP) \sup_{\mu} \inf_{x \mid Ax=b} \mathcal{L}_{DP}(x, \mu)$$

# Ajout de contraintes quadratiques redondantes avant d'effectuer la bidualisation

$$f_j(x) = 0 \text{ sur } \{x : Ax = b\}$$

$$\mathfrak{J} = \left\{ f_j(x) = x^T C_j x + q_j^T x + \alpha_j : j \in J \right\}$$

# Ajout de contraintes quadratiques redondantes avant d'effectuer la bidualisation

$$f_j(x) = 0 \text{ sur } \{x : Ax = b\}$$

$$\mathfrak{J} = \left\{ f_j(x) = x^T C_j x + q_j^T x + \alpha_j : j \in \mathcal{J} \right\}$$

Ajouter  $f_j(x) = 0 \forall j$  à (P) donne :

# Ajout de contraintes quadratiques redondantes avant d'effectuer la bidualisation

$$f_j(x) = 0 \text{ sur } \{x : Ax = b\}$$

$$\mathfrak{J} = \left\{ f_j(x) = x^T C_j x + q_j^T x + \alpha_j : j \in J \right\}$$

Ajouter  $f_j(x) = 0 \forall j$  à (P) donne :

- $\mathcal{L}_{DT_{\mathfrak{J}}}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \sum_{j \in J} \omega_j f_j(x)$   
→ meilleure borne !

# Ajout de contraintes quadratiques redondantes avant d'effectuer la bidualisation

$$f_j(x) = 0 \text{ sur } \{x : Ax = b\}$$

$$\mathfrak{J} = \left\{ f_j(x) = x^T C_j x + q_j^T x + \alpha_j : j \in J \right\}$$

Ajouter  $f_j(x) = 0 \forall j$  à (P) donne :

- $\mathcal{L}_{DT_3}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \sum_{j \in J} \omega_j f_j(x)$   
→ meilleure borne !
- $\mathcal{L}_{DP_3}(x, \mu, \omega) = \mathcal{L}_{DP}(x, \mu, \omega) \quad f_j(x) = 0 \text{ car } Ax = b!$

# Ajout de contraintes quadratiques redondantes avant d'effectuer la bidualisation

$$f_j(x) = 0 \text{ sur } \{x : Ax = b\}$$

$$\mathfrak{J} = \left\{ f_j(x) = x^T C_j x + q_j^T x + \alpha_j : j \in J \right\}$$

Ajouter  $f_j(x) = 0 \forall j$  à (P) donne :

- $\mathcal{L}_{DT_{\mathfrak{J}}}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \sum_{j \in J} \omega_j f_j(x)$   
→ meilleure borne !
- $\mathcal{L}_{DP_{\mathfrak{J}}}(x, \mu, \omega) = \mathcal{L}_{DP}(x, \mu, \omega) \quad f_j(x) = 0 \text{ car } Ax = b!$

## Proposition

Pour tout ensemble  $\mathfrak{J}$ ,  $(DP)_{\mathfrak{J}}$  est équivalent à  $(DP)$ ,  
mais  $(DT)_{\mathfrak{J}}$  est généralement meilleur que  $(DT)$

# Une condition suffisante pour avoir $(DT)_{\mathfrak{J}}=(DP)$

$\forall \mathfrak{J}$  on a :  $(DT)_{\mathfrak{J}} \leq (DP) \leq (P)$

# Une condition suffisante pour avoir $(DT)_{\mathfrak{J}}=(DP)$

Si  $\mathcal{L}_{DT_{\mathfrak{J}}}$  est convexe alors  $(DT)_{\mathfrak{J}}=(DP)\leq(P)$

## Proposition

Soit  $\mu^*$  une solution optimale de  $(DP)$ . S'il existe  $\omega^*$  tel que  $\mathcal{L}_{DT_{\mathfrak{J}}}(x, \mu^*, \lambda, \omega^*)$  est **convexe**, alors les valeurs optimales de  $(DT)_{\mathfrak{J}}$ ,  $(SDP)_{\mathfrak{J}}$  et  $(DP)$  sont **égales**



# Une condition suffisante pour avoir $(DT)_{\mathfrak{J}}=(DP)$

Si  $\mathcal{L}_{DT_{\mathfrak{J}}}$  est convexe alors  $(DT)_{\mathfrak{J}}=(DP)\leq(P)$

## Proposition

Soit  $\mu^*$  une solution optimale de  $(DP)$ . S'il existe  $\omega^*$  tel que  $\mathcal{L}_{DT_{\mathfrak{J}}}(x, \mu^*, \lambda, \omega^*)$  est **convexe**, alors les valeurs optimales de  $(DT)_{\mathfrak{J}}$ ,  $(SDP)_{\mathfrak{J}}$  et  $(DP)$  sont **égales**

# Une condition suffisante pour avoir $(DT)_{\mathfrak{J}}=(DP)$

Si  $\mathcal{L}_{DT_{\mathfrak{J}}}$  est convexe alors  $(DT)_{\mathfrak{J}}=(DP)\leq(P)$

## Proposition

Soit  $\mu^*$  une solution optimale de  $(DP)$ . S'il existe  $\omega^*$  tel que  $\mathcal{L}_{DT_{\mathfrak{J}}}(x, \mu^*, \lambda, \omega^*)$  est **convexe**, alors les valeurs optimales de  $(DT)_{\mathfrak{J}}$ ,  $(SDP)_{\mathfrak{J}}$  et  $(DP)$  sont **égales**

On retrouve dans la formulation semidéfinie les contraintes quadratiques linéarisées :

$$(DT)_{\mathfrak{J}} \Leftrightarrow (SDP)_{\mathfrak{J}} \left\{ \begin{array}{l} \min \quad Q \bullet X + c^T x \\ \text{s.c.} \quad Ax = b \\ B_i \bullet X + d_i^T x = (\text{ou } \leq) e_i \quad i \in I \\ C_j \bullet X + q_j^T x + \alpha_j = 0 \quad j \in J \\ \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succcurlyeq 0 \end{array} \right.$$

# Deux convexifications équivalentes dans le cas 0-1

$$(P)_{0-1} \left\{ \begin{array}{l} \min \quad x^T Q x + c^T x \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ \quad \quad Ax = b \\ \quad \quad x_i^2 = x_i \Leftrightarrow x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

# Deux convexifications équivalentes dans le cas 0-1

$$(P)_{0-1} \left\{ \begin{array}{l} \min \quad x^T Q x + c^T x \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ \quad \quad Ax = b \text{ et } (Ax - b)^2 = 0 \\ \quad \quad x_i^2 = x_i \Leftrightarrow x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $\mathcal{L}_{DT_C}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \omega (Ax - b)^2$

# Deux convexifications équivalentes dans le cas 0-1

$$(P)_{0-1} \left\{ \begin{array}{l} \min \quad x^T Q x + c^T x \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ \quad \quad Ax = b \text{ et } (Ax - b)^2 = 0 \\ \quad \quad x_i^2 = x_i \Leftrightarrow x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $\mathcal{L}_{DT_C}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \omega (Ax - b)^2$
- Convexification réussie : (DP) peut être formulé comme un programme semidéfini

# Deux convexifications équivalentes dans le cas 0-1

$$(P)_{0-1} \left\{ \begin{array}{l} \min \quad x^T Q x + c^T x \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ \quad \quad Ax = b \text{ et } (Ax - b)^2 = 0 \\ \quad \quad x_i^2 = x_i \Leftrightarrow x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $\mathcal{L}_{DT_C}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \omega (Ax - b)^2$
- Convexification réussie : (DP) peut être formulé comme un programme semidéfini
- Il suffit d'ajouter  $A^T A \bullet X - 2b^T Ax + b^2 = 0$  dans le PSD

# Deux convexifications équivalentes dans le cas 0-1

$$(P)_{0-1} \left\{ \begin{array}{l} \min \quad x^T Q x + c^T x \\ \text{s.c.} \quad x^T B_i x + d_i^T x = (\text{ou } \leq) e_i \quad i \in I = \{1, \dots, m\} \\ \quad \quad Ax = b \text{ et } (Ax - b)^2 = 0 \\ \quad \quad x_i^2 = x_i \Leftrightarrow x_i \in \{0, 1\} \quad \forall i \in \{1, \dots, n\} \end{array} \right.$$

- $\mathcal{L}_{DT_C}(x, \mu, \lambda, \omega) = \mathcal{L}_{DT}(x, \mu, \lambda) + \omega (Ax - b)^2$
- Convexification réussie : (DP) peut être formulé comme un programme semidéfini
- Il suffit d'ajouter  $A^T A \bullet X - 2b^T Ax + b^2 = 0$  dans le PSD
- Dans le cas non-booléen,  $(Ax - b)^2$  ne convexifie pas toujours le Lagrangien

# Une deuxième convexification (valable dans le cas général)

## Théorème

Soient  $A$  et  $Q$  respectivement une matrice  $p \times n$  et une matrice  $n \times n$ . Si  $Q$  est positive sur  $L = \ker(A)$  alors il existe une combinaison linéaire des fonctions quadratiques  $q_{ij}(x) = x_i(a_j^T x - b_j)$  pour  $i \in \{1, \dots, n\}$  et  $j \in \{1, \dots, p\}$  qui **convexifie** la forme quadratique  $x^T Q x$  sur  $\mathbb{R}^n$  tout entier.



# Une deuxième convexification (valable dans le cas général)

## Théorème

Soient  $A$  et  $Q$  respectivement une matrice  $p \times n$  et une matrice  $n \times n$ . Si  $Q$  est positive sur  $L = \ker(A)$  alors il existe une combinaison linéaire des fonctions quadratiques  $q_{ij}(x) = x_i(a_j^T x - b_j)$  pour  $i \in \{1, \dots, n\}$  et  $j \in \{1, \dots, p\}$  qui **convexifie** la forme quadratique  $x^T Q x$  sur  $\mathbb{R}^n$  tout entier.

# Une deuxième convexification (valable dans le cas général)

## Théorème

Soient  $A$  et  $Q$  respectivement une matrice  $p \times n$  et une matrice  $n \times n$ . Si  $Q$  est positive sur  $L = \ker(A)$  alors il existe une combinaison linéaire des fonctions quadratiques  $q_{ij}(x) = x_i(a_j^T x - b_j)$  pour  $i \in \{1, \dots, n\}$  et  $j \in \{1, \dots, p\}$  qui **convexifie** la forme quadratique  $x^T Q x$  sur  $\mathbb{R}^n$  tout entier.


Formulation semidéfinie de la relaxation lagrangienne partielle (DP)

$$(SDP_P) \left\{ \begin{array}{l} \min \quad Q \bullet X + c^T x \\ \text{s.c.} \quad Ax = b \\ \quad B_i \bullet X + d_i^T x = (\text{ou } \leq) e_i \quad i \in I \\ \quad \sum_{k=1}^n A_{jk} X_{ki} - b_j x_i = 0 \quad i \in \{1, \dots, n\} \quad j \in \{1, \dots, p\} \\ \quad (X_{ii} = x_i) \quad (i \in \{1, \dots, n\}) \\ \quad \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succcurlyeq 0 \end{array} \right.$$

# Ces deux relaxations semidéfinies permettent d'atteindre la valeur de $(DP)$ (cas 0-1)

## corollaire

*$(DP)$  est une limite pour les relaxations semidéfinies utilisant des contraintes redondantes construites à partir de  $Ax = b$*



# Preuve directe de l'équivalence sans passer par la dualité lagrangienne

Ici cas simplifié : une seule contrainte linéaire

## Proposition

Soit  $(X, x) \in \mathcal{S}_n \times \mathbb{R}$  vérifiant  $cc^T \bullet X = d^2$ ,  $c^T x = d$  et  $\begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0$ ,  
alors  $(X, x)$  vérifie  $\sum_{j=1}^n c_j X_{ij} = dx_i \forall i \in \{1, \dots, n\}$  (réciproque évidente)

# Preuve directe de l'équivalence sans passer par la dualité lagrangienne

Ici cas simplifié : une seule contrainte linéaire

## Proposition

Soit  $(X, x) \in \mathcal{S}_n \times \mathbb{R}$  vérifiant  $cc^T \bullet X = d^2$ ,  $c^T x = d$  et  $\begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0$ ,  
alors  $(X, x)$  vérifie  $\sum_{j=1}^n c_j X_{ij} = dx_i \forall i \in \{1, \dots, n\}$  (réciproque évidente)

# Preuve directe de l'équivalence sans passer par la dualité lagrangienne

Ici cas simplifié : une seule contrainte linéaire

## Proposition

Soit  $(X, x) \in S_n \times \mathbb{R}$  vérifiant  $cc^T \bullet X = d^2$ ,  $c^T x = d$  et  $\begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0$ ,  
alors  $(X, x)$  vérifie  $\sum_{j=1}^n c_j X_{ij} = dx_i \forall i \in \{1, \dots, n\}$  (réciproque évidente)

Preuve.

$$cc^T \bullet X = d^2 \Rightarrow cc^T \bullet (X - xx^T) + (c^T x)^2 = d^2$$

$$\text{Donc } cc^T \bullet (X - xx^T) = 0$$

$$\Rightarrow cc^T (X - xx^T) = 0$$

# Preuve directe de l'équivalence sans passer par la dualité lagrangienne

Ici cas simplifié : une seule contrainte linéaire

## Proposition

Soit  $(X, x) \in S_n \times \mathbb{R}$  vérifiant  $cc^T \bullet X = d^2$ ,  $c^T x = d$  et  $\begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0$ ,  
alors  $(X, x)$  vérifie  $\sum_{j=1}^n c_j X_{ij} = dx_i \forall i \in \{1, \dots, n\}$  (réciproque évidente)

Preuve.

$$cc^T \bullet X = d^2 \Rightarrow cc^T \bullet (X - xx^T) + (c^T x)^2 = d^2$$

$$\text{Donc } cc^T \bullet (X - xx^T) = 0$$

$$\Rightarrow cc^T (X - xx^T) = 0$$

$$\forall k, j \in \{1, \dots, n\} \quad c_k \left( \sum_{i=1}^n c_i (X_{ij} - x_i x_j) \right) = 0.$$

- $c = 0$  : résultat évident

# Preuve directe de l'équivalence sans passer par la dualité lagrangienne

Ici cas simplifié : une seule contrainte linéaire

## Proposition

Soit  $(X, x) \in S_n \times \mathbb{R}$  vérifiant  $cc^T \bullet X = d^2$ ,  $c^T x = d$  et  $\begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0$ ,  
alors  $(X, x)$  vérifie  $\sum_{j=1}^n c_j X_{ij} = dx_i \forall i \in \{1, \dots, n\}$  (réciproque évidente)

Preuve.

$$cc^T \bullet X = d^2 \Rightarrow cc^T \bullet (X - xx^T) + (c^T x)^2 = d^2$$

$$\text{Donc } cc^T \bullet (X - xx^T) = 0$$

$$\Rightarrow cc^T (X - xx^T) = 0$$

$$\forall k, j \in \{1, \dots, n\} c_k \left( \sum_{i=1}^n c_i (X_{ij} - x_i x_j) \right) = 0.$$

- $c = 0$  : résultat évident
- Il existe  $k_0$  tel que  $c_{k_0} \neq 0$ .

$$\forall j \in \{1, \dots, n\} \sum_{i=1}^n c_i X_{ij} = x_j \sum_{i=1}^n c_i x_i = dx_j.$$



# Application : le Problème k-cluster

- $G = (V, E)$  un graphe non orienté de  $n$  sommets et un entier  $1 \leq k \leq n$

## Application : le Problème k-cluster

- $G = (V, E)$  un graphe non orienté de  $n$  sommets et un entier  $1 \leq k \leq n$
- Chaque arête  $[v_i, v_j]$  porte un poids  $W_{ij}$  (on a  $W_{ij} = 0$  pour tout  $i$  dans  $\{1, \dots, n\}$ )

## Application : le Problème k-cluster

- $G = (V, E)$  un graphe non orienté de  $n$  sommets et un entier  $1 \leq k \leq n$
- Chaque arête  $[v_i, v_j]$  porte un poids  $W_{ij}$  (on a  $W_{ij} = 0$  pour tout  $i$  dans  $\{1, \dots, n\}$ )
- Trouver le sous-graphe de  $k$  sommets de poids maximal

## Application : le Problème k-cluster

- $G = (V, E)$  un graphe non orienté de  $n$  sommets et un entier  $1 \leq k \leq n$
- Chaque arête  $[v_i, v_j]$  porte un poids  $W_{ij}$  (on a  $W_{ij} = 0$  pour tout  $i$  dans  $\{1, \dots, n\}$ )
- Trouver le sous-graphe de  $k$  sommets de poids maximal

## Application : le Problème k-cluster

- $G = (V, E)$  un graphe non orienté de  $n$  sommets et un entier  $1 \leq k \leq n$
- Chaque arête  $[v_i, v_j]$  porte un poids  $W_{ij}$  (on a  $W_{ij} = 0$  pour tout  $i$  dans  $\{1, \dots, n\}$ )
- Trouver le sous-graphe de  $k$  sommets de poids maximal

$$(KC)_{\{0,1\}} \left\{ \begin{array}{l} \max \quad \frac{1}{2} W \bullet X \\ \text{s.c.} \quad \sum_{i=1}^n x_i = k \\ \quad \quad x \in \{0, 1\}^n \\ \quad \quad X = xx^T \end{array} \right.$$

# Application : le Problème k-cluster

- $G = (V, E)$  un graphe non orienté de  $n$  sommets et un entier  $1 \leq k \leq n$
- Chaque arête  $[v_i, v_j]$  porte un poids  $W_{ij}$  (on a  $W_{ii} = 0$  pour tout  $i$  dans  $\{1, \dots, n\}$ )
- Trouver le sous-graphe de  $k$  sommets de poids maximal

$$(KC)_{\{0,1\}} \begin{cases} \max & \frac{1}{2} W \bullet X \\ \text{s.c.} & \sum_{i=1}^n x_i = k \\ & x \in \{0, 1\}^n \\ & X = xx^T \end{cases}$$

$$(KC)_{\{-1,1\}} \begin{cases} \max & \frac{1}{8} \sum_{i=1}^n \sum_{j \neq i} W_{ij} (1 + y_i y_j + y_i + y_j) \\ \text{s.c.} & \sum_{i=1}^n y_i = 2k - n \\ & y \in \{-1, 1\}^n \end{cases}$$

# Relaxations semidéfinies "basiques"

# Relaxations semidéfinies "basiques"

$$(KC\ SDP)_{\{0,1\}} \left\{ \begin{array}{l} \text{Maximiser} \quad \frac{1}{2} W \bullet X \\ \text{Sous contraintes} \quad \mathbf{e}_n^T x = k \\ \mathbf{d}(X) = x \\ X' = \begin{bmatrix} 1 & x \\ x^T & X \end{bmatrix} \succeq 0 \end{array} \right.$$



# Relaxations semidéfinies "basiques"

$$(KC\ SDP)_{\{0,1\}} \left\{ \begin{array}{l} \text{Maximiser} \quad \frac{1}{2} W \bullet X \\ \text{Sous contraintes} \quad \mathbf{e}_n^T x = k \\ \mathbf{d}(X) = x \\ X' = \begin{bmatrix} 1 & x \\ x^T & X \end{bmatrix} \succeq 0 \end{array} \right.$$

$$(KC\ SDP)_{\{-1,1\}} \left\{ \begin{array}{l} \max \quad \frac{1}{8} \sum_{i=1}^n \sum_{j \neq i} W_{ij} (1 + Y_{ij} + Y_{0i} + Y_{0j}) \\ \text{s.c.} \quad \sum_{i=1}^n Y_{0i} = 2k - n \\ \mathbf{d}(Y) = \mathbf{e}_{n+1} \\ Y \succeq 0 \end{array} \right.$$

# Construction d'une meilleure relaxation semidéfinie

$$(PL)_{KC} \left\{ \begin{array}{l} \max \quad \frac{1}{2} W \bullet X \\ \text{s.c. :} \\ (a) \quad \sum_{i=1}^n x_i = \mathbf{e}_n^T x = k \\ (b) \quad \sum_{i < j} X_{ij} + \sum_{j > i} X_{ij} = (k-1)x_i \quad i \in \{1, \dots, n\} \\ (c) \quad X_{ij} \geq 0 \quad i < j \notin E \\ (d) \quad X_{ij} \leq x_i; X_{ij} \leq x_j \quad i < j \notin E \\ \quad \quad 0 \leq x_i \leq 1 \quad i \in \{1, \dots, n\} \end{array} \right.$$

# Construction d'une meilleure relaxation semidéfinie

$$(PL)_{KC} \left\{ \begin{array}{l} \max \quad \frac{1}{2} W \bullet X \\ \text{s.c. :} \\ (a) \quad \sum_{i=1}^n x_i = \mathbf{e}_n^T x = k \\ (b) \quad \sum_{i < j} X_{ij} + \sum_{j > i} X_{ij} = (k-1)x_i \quad i \in \{1, \dots, n\} \\ (c) \quad X_{ij} \geq 0 \quad i < j \notin E \\ (d) \quad X_{ij} \leq x_i; X_{ij} \leq x_j \quad i < j \notin E \\ \quad \quad 0 \leq x_i \leq 1 \quad i \in \{1, \dots, n\} \end{array} \right.$$

$$(SDP)_{KC} \left\{ \begin{array}{l} \max \quad \frac{1}{2} W \bullet X \\ \text{s.c. :} \\ (a') \quad \mathbf{e}_n^T x = k, \quad (\mathbf{e}_n \mathbf{e}_n^T \bullet X - 2k \mathbf{e}_n^T x + k^2 = 0) \\ (b') \quad \sum_{i=1}^n X_{ij} = kx_j \quad \forall j \in \{1, \dots, n\} \\ (c') \quad X_{ij} \geq 0 \quad i < j \in \{1, \dots, n\} \\ (d') \quad X_{ij} \leq x_i; X_{ij} \leq x_j \quad i < j \in \{1, \dots, n\} \\ \quad \quad \mathbf{d}(X) = x; X - xx^T \succeq 0 \end{array} \right.$$

# k-cluster : Relaxations semidéfinie et Lagrangienne partielle

Formulation semidéfinie de la relaxation Lagrangienne partielle de :

# k-cluster : Relaxations semidéfinie et Lagrangienne partielle

Formulation semidéfinie de la relaxation Lagrangienne partielle de :

$$\left\{ \begin{array}{ll} \max & \frac{1}{2}x^T Wx \\ \text{s.c.} & \sum_{i=1}^n x_i = k \\ & x_i^2 = x_i \quad i = 1, \dots, n \\ & x_i x_j \geq 0 \quad i < j \in \{1, \dots, n\} \\ & x_i x_j \leq x_i; x_i x_j \leq x_j \quad i < j \in \{1, \dots, n\} \end{array} \right.$$

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

4. Approche par Programmation Semidéfinie

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

## 4.b.5. Amélioration des relaxations Quadratiques Convexes

Programme Quadratique en variables 0-1 soumis à des contraintes linéaires :

$$(QL) \quad \begin{cases} \min & x^T Qx + c^T x \\ \text{s.c.} & Ax = b \\ & x \in \{0, 1\}^n \end{cases}$$

$Q$  est quelconque donc problème non convexe même en relâchant les contraintes 0-1

## 4.b.5. Amélioration des relaxations Quadratiques Convexes

Programme Quadratique en variables 0-1 soumis à des contraintes linéaires :

$$(QL) \quad \begin{cases} \min & x^T Qx + c^T x \\ \text{s.c.} & Ax = b \\ & x \in \{0, 1\}^n \end{cases}$$

$Q$  est quelconque donc problème non convexe même en relâchant les contraintes 0-1

**Idée de départ** : "Capter" la qualité des bornes semidéfinies dans une **relaxation quadratique convexe** (très rapide à résoudre)



## 4.b.5. Amélioration des relaxations Quadratiques Convexes

Programme Quadratique en variables 0-1 soumis à des contraintes linéaires :

$$(QL) \quad \begin{cases} \min & x^T Qx + c^T x \\ \text{s.c.} & Ax = b \\ & x \in \{0, 1\}^n \end{cases}$$

$Q$  est quelconque donc problème non convexe même en relâchant les contraintes 0-1

**Idee de départ** : "Capter" la qualité des bornes semidéfinies dans une **relaxation quadratique convexe** (très rapide à résoudre)

**Principe de l'approche** :

- ➊ **Ajouter** un terme quadratique à la fonction pour la convexifier puis relaxation **continue** ( $x \in [0, 1]^n$ )

## 4.b.5. Amélioration des relaxations Quadratiques Convexes

Programme Quadratique en variables 0-1 soumis à des contraintes linéaires :

$$(QL) \quad \begin{cases} \min & x^T Qx + c^T x \\ \text{s.c.} & Ax = b \\ & x \in \{0, 1\}^n \end{cases}$$

$Q$  est quelconque donc problème non convexe même en relâchant les contraintes 0-1

**Idee de départ** : "Capter" la qualité des bornes semidéfinies dans une **relaxation quadratique convexe** (très rapide à résoudre)

**Principe de l'approche** :

- ➊ **Ajouter** un terme quadratique à la fonction pour la convexifier puis relaxation **continue** ( $x \in [0, 1]^n$ )
- ➋ On peut obtenir le "meilleur" terme possible en résolvant un programme semidéfini

# Convexification d'un programme quadratique (1)

**Première idée** : ajouter  $K \sum_{i=1}^n (x_i^2 - x_i)$  à la fonction  $x^T Qx + c^T x$  avec  $K$  "assez grand" : fonction nulle pour  $x$  admissible (donc vérifiant  $x \in \{0, 1\}^n$ )

# Convexification d'un programme quadratique (1)

**Première idée** : ajouter  $K \sum_{i=1}^n (x_i^2 - x_i)$  à la fonction  $x^T Qx + c^T x$  avec  $K$  "assez grand" : fonction nulle pour  $x$  admissible (donc vérifiant  $x \in \{0, 1\}^n$ )

- Fonction convexe :  $Q + KI_n \succcurlyeq 0$

# Convexification d'un programme quadratique (1)

**Première idée** : ajouter  $K \sum_{i=1}^n (x_i^2 - x_i)$  à la fonction  $x^T Qx + c^T x$  avec  $K$  "assez grand" : fonction nulle pour  $x$  admissible (donc vérifiant  $x \in \{0, 1\}^n$ )

- Fonction convexe :  $Q + KI_n \succcurlyeq 0$
- On prend  $K \geq -\min_j \lambda_j(Q)$

# Convexification d'un programme quadratique (1)

**Première idée** : ajouter  $K \sum_{i=1}^n (x_i^2 - x_i)$  à la fonction  $x^T Qx + c^T x$  avec  $K$  "assez grand" : fonction nulle pour  $x$  admissible (donc vérifiant  $x \in \{0, 1\}^n$ )

- Fonction convexe :  $Q + KI_n \succcurlyeq 0$
- On prend  $K \geq -\min_j \lambda_j(Q)$
- On obtient une relaxation quadratique convexe en relâchant  $x \in \{0, 1\}^n$  en  $x \in [0, 1]^n$

# Convexification d'un programme quadratique (1)

**Première idée** : ajouter  $K \sum_{i=1}^n (x_i^2 - x_i)$  à la fonction  $x^T Qx + c^T x$  avec  $K$  "assez grand" : fonction nulle pour  $x$  admissible (donc vérifiant  $x \in \{0, 1\}^n$ )

- Fonction convexe :  $Q + KI_n \succcurlyeq 0$
- On prend  $K \geq -\min_j \lambda_j(Q)$
- On obtient une relaxation quadratique convexe en relâchant  $x \in \{0, 1\}^n$  en  $x \in [0, 1]^n$
- Amélioration possible : ajouter  $\sum_{i=1}^n K_i (x_i^2 - x_i)$

# Convexification d'un programme quadratique (1)

**Première idée** : ajouter  $K \sum_{i=1}^n (x_i^2 - x_i)$  à la fonction  $x^T Qx + c^T x$  avec  $K$  "assez grand" : fonction nulle pour  $x$  admissible (donc vérifiant  $x \in \{0, 1\}^n$ )

- Fonction convexe :  $Q + KI_n \succcurlyeq 0$
- On prend  $K \geq -\min_j \lambda_j(Q)$
- On obtient une relaxation quadratique convexe en relâchant  $x \in \{0, 1\}^n$  en  $x \in [0, 1]^n$
- Amélioration possible : ajouter  $\sum_{i=1}^n K_i (x_i^2 - x_i)$
- En fait, on peut considérer une approche encore plus générale en utilisant également les contraintes  $Ax = b$ !



## Convexification d'un programme quadratique (2)

Amélioration de l'approche :

⇒ Ajouter une combinaison linéaire des fonctions  $h_i(x) = x_i^2 - x_i$  ( $i = 1, \dots, n$ ) et  $g_{ij}(x) = \sum_{k=1}^n A_{jk} x_k x_i - b_j x_i$  ( $j = 1, \dots, p$  et  $i = 1, \dots, n$ ) à la fonction  $x^T Q x + c^T x$  : fonction nulle pour  $x$  admissible (vérifiant  $x \in \{0, 1\}^n$  et  $Ax = b$ )

## Convexification d'un programme quadratique (2)

Amélioration de l'approche :

⇒ Ajouter une combinaison linéaire des fonctions  $h_i(x) = x_i^2 - x_i$  ( $i = 1, \dots, n$ ) et  $g_{ij}(x) = \sum_{k=1}^n A_{jk} x_k x_i - b_j x_i$  ( $j = 1, \dots, p$  et  $i = 1, \dots, n$ ) à la fonction  $x^T Q x + c^T x$  : fonction nulle pour  $x$  admissible (vérifiant  $x \in \{0, 1\}^n$  et  $Ax = b$ )

⇒ On reconnaît les contraintes "produit" de l'approche linéaire d'Adams-Sharali et qui jouent également un rôle important dans la formulation semidéfinie de la relaxation Lagrangienne partielle de (QL) !

## Convexification d'un programme quadratique (2)

Amélioration de l'approche :

⇒ Ajouter une combinaison linéaire des fonctions  $h_i(x) = x_i^2 - x_i$  ( $i = 1, \dots, n$ ) et  $g_{ij}(x) = \sum_{k=1}^n A_{jk} x_k x_i - b_j x_i$  ( $j = 1, \dots, p$  et  $i = 1, \dots, n$ ) à la fonction  $x^T Qx + c^T x$  : fonction nulle pour  $x$  admissible (vérifiant  $x \in \{0, 1\}^n$  et  $Ax = b$ )

⇒ On reconnaît les contraintes "produit" de l'approche linéaire d'Adams-Sharali et qui jouent également un rôle important dans la formulation semidéfinie de la relaxation Lagrangienne partielle de (QL) !

Trouver la meilleure combinaison linéaire ?

## Convexification d'un programme quadratique (2)

Amélioration de l'approche :

⇒ Ajouter une combinaison linéaire des fonctions  $h_i(x) = x_i^2 - x_i$  ( $i = 1, \dots, n$ ) et  $g_{ij}(x) = \sum_{k=1}^n A_{jk} x_k x_i - b_j x_i$  ( $j = 1, \dots, p$  et  $i = 1, \dots, n$ ) à la fonction  $x^T Qx + c^T x$  : fonction nulle pour  $x$  admissible (vérifiant  $x \in \{0, 1\}^n$  et  $Ax = b$ )

⇒ On reconnaît les contraintes "produit" de l'approche linéaire d'Adams-Sharali et qui jouent également un rôle important dans la formulation semidéfinie de la relaxation Lagrangienne partielle de (QL) !

Trouver la meilleure combinaison linéaire ?

$$\sup_{\alpha, \beta} \inf_{x \in [0, 1]^n \cap \{x: Ax=b\}} x^T Qx + c^T x + \sum_{i=1}^n \alpha_i (x_i^2 - x_i) + \sum_{j=1}^p \sum_{i=1}^n \beta_{ij} (\sum_{k=1}^n A_{jk} x_k x_i - b_j x_i)$$

## Convexification d'un programme quadratique (2)

Amélioration de l'approche :

⇒ Ajouter une combinaison linéaire des fonctions  $h_i(x) = x_i^2 - x_i$  ( $i = 1, \dots, n$ ) et  $g_{ij}(x) = \sum_{k=1}^n A_{jk} x_k x_i - b_j x_i$  ( $j = 1, \dots, p$  et  $i = 1, \dots, n$ ) à la fonction  $x^T Qx + c^T x$  : fonction nulle pour  $x$  admissible (vérifiant  $x \in \{0, 1\}^n$  et  $Ax = b$ )

⇒ On reconnaît les contraintes "produit" de l'approche linéaire d'Adams-Sharali et qui jouent également un rôle important dans la formulation semidéfinie de la relaxation Lagrangienne partielle de (QL) !

Trouver la meilleure combinaison linéaire ?

$$\sup_{\alpha, \beta} \inf_{x \in [0, 1]^n \cap \{x: Ax=b\}} x^T Qx + c^T x + \sum_{i=1}^n \alpha_i (x_i^2 - x_i) + \sum_{j=1}^p \sum_{i=1}^n \beta_{ij} (\sum_{k=1}^n A_{jk} x_k x_i - b_j x_i)$$

Le dual d'une formulation équivalente de ce problème peut s'interpréter comme un programme semidéfini !

## Convexification d'un programme quadratique (3)

$$\sup_{\alpha, \beta} \inf_{x \in [0, 1]^n \cap \{x: Ax=b\}} x^T Qx + c^T x + \sum_{i=1}^n \alpha_i (x_i^2 - x_i) \\ + \sum_{j=1}^p \sum_{i=1}^n \beta_{ij} (\sum_{k=1}^n A_{jk} x_k x_i - b_j x_i)$$

On remplace  $x \in [0, 1]^n$  par les contraintes **convexes**  $x_i^2 - x_i \leq 0$

# Convexification d'un programme quadratique (3)

$$\sup_{\alpha, \beta} \inf_{x \in [0, 1]^n \cap \{x: Ax=b\}} x^T Q x + c^T x + \sum_{i=1}^n \alpha_i (x_i^2 - x_i) + \sum_{j=1}^p \sum_{i=1}^n \beta_{ij} (\sum_{k=1}^n A_{jk} x_k x_i - b_j x_i)$$

On remplace  $x \in [0, 1]^n$  par les contraintes **convexes**  $x_i^2 - x_i \leq 0$

$$(SDP_P) \left\{ \begin{array}{l} \min \quad Q \bullet X + c^T x \\ \text{s.c.} \quad Ax = b \\ \sum_{k=1}^n A_{jk} X_{ki} - b_j x_i = 0 \quad i \in \{1, \dots, n\} \quad j \in \{1, \dots, p\} \\ X_{ii} = x_i \quad (i \in \{1, \dots, n\}) \\ \begin{bmatrix} 1 & x^T \\ x & X \end{bmatrix} \succeq 0 \end{array} \right.$$

# Convexification d'un programme quadratique (4)

- **Conséquence** : Le programme quadratique convexe obtenu a la même valeur que le programme semidéfini ( $SDP_P$ )



## Convexification d'un programme quadratique (4)

- **Conséquence** : Le programme quadratique convexe obtenu a la même valeur que le programme semidéfini ( $SDP_P$ )
- **Intérêt** : Utiliser ce programme quadratique convexe dans une méthode de séparation/évaluation (Branch&Bound) à la place de la PSD !

## Convexification d'un programme quadratique (4)

- **Conséquence** : Le programme quadratique convexe obtenu a la même valeur que le programme semidéfini ( $SDP_P$ )
- **Intérêt** : Utiliser ce programme quadratique convexe dans une méthode de séparation/évaluation (Branch&Bound) à la place de la PSD !
- Résolution d'un seul PSD : on a "**capté**" la qualité de l'approche semidéfinie dans une approche quadratique convexe.

# Plan du cours

1. Introduction

2. Linéarisations

3. Approches Lagrangiennes

4. Approche par Programmation Semidéfinie

- a. Bases de la Programmation Semidéfinie
- b. Application à la Programmation Quadratique en 0-1
  - 1. Le nombre de Lovász
  - 2. Relaxation SDP en  $\{0, 1\}$
  - 3. Relaxation SDP en  $\{-1, 1\}$
  - 4. Liens avec l'approche Lagrangienne
  - 5. Amélioration des relaxations Quadratiques Convexes
  - 6. Problèmes SDLS et contrainte sphérique

## 4.b.6. Problèmes SDLS et contrainte sphérique

### SDLS : SemiDefinite Least Squares

Programme Quadratique en variables bivalentes :

$$(Q) \quad \begin{cases} \max & Q \bullet X \\ \text{s.c.} & Q_i \bullet X \geq 0 \quad i \in I = \{1, \dots, m\} \\ & x_i \in \{-1, 1\} \quad \forall i \in \{1, \dots, n\} \\ & X = xx^T \end{cases}$$

## 4.b.6. Problèmes SDLS et contrainte sphérique

### SDLS : SemiDefinite Least Squares

Programme Quadratique en variables bivalentes :

$$(Q) \begin{cases} \max & Q \bullet X \\ \text{s.c.} & Q_i \bullet X \geq 0 \quad i \in I = \{1, \dots, m\} \\ & x_i \in \{-1, 1\} \quad \forall i \in \{1, \dots, n\} \\ & X = xx^T \end{cases}$$

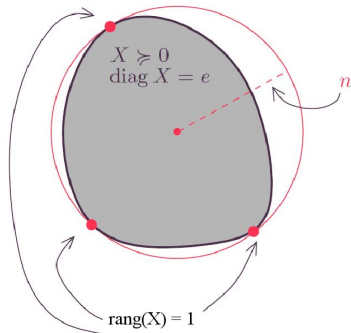
$X$  est de rang 1 et appartient à

$$\mathcal{C} = \{X \in \mathcal{S}_n : X \succcurlyeq 0, X_{jj} = 1 \forall j \in \{1, \dots, n\}\}$$

# La Contrainte Sphérique

## Théorème


$X \in \mathcal{C}$  est de rang 1 est équivalent à  
 $\|X\|^2 = X \bullet X = \sum_{i=1}^n \sum_{j=1}^n X_{ij}^2 = n^2$



# La Contrainte Sphérique

## Théorème

$X \in \mathcal{C}$  est de rang 1 est équivalent à  
 $\|X\|^2 = X \bullet X = \sum_{i=1}^n \sum_{j=1}^n X_{ij}^2 = n^2$



- $X$  appartient donc à la **sphère** de centre 0 et de rayon  $n$  (au sens de la norme associée à  $\bullet$ )

# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans (Q) puis dualiser cette dernière contrainte



# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans (Q) puis dualiser cette dernière contrainte
- $\alpha$  : le multiplicateur de Lagrange associé

# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans (Q) puis dualiser cette dernière contrainte
- $\alpha$  : le multiplicateur de Lagrange associé
- Pour  $\alpha = 0$ , on retrouve la relaxation semidéfinie de base

# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans (Q) puis dualiser cette dernière contrainte
- $\alpha$  : le multiplicateur de Lagrange associé
- Pour  $\alpha = 0$ , on retrouve la relaxation semidéfinie de base
- Pour  $\alpha \neq 0$  Le Lagrangien vaut :  $L(X, \alpha) = Q \bullet X + \frac{\alpha}{2} (n^2 - X \bullet X)$   
 $= \frac{\alpha}{2} n^2 + \frac{\alpha}{2} \left( \frac{Q \bullet Q}{\alpha^2} - \left( X - \frac{Q}{\alpha} \right) \bullet \left( X - \frac{Q}{\alpha} \right) \right)$   
 $= \frac{\alpha}{2} n^2 + \frac{1}{2\alpha} \|Q\|^2 - \frac{\alpha}{2} \left\| X - \frac{Q}{\alpha} \right\|^2$

# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans (Q) puis dualiser cette dernière contrainte
- $\alpha$  : le multiplicateur de Lagrange associé
- Pour  $\alpha = 0$ , on retrouve la relaxation semidéfinie de base
- Pour  $\alpha \neq 0$  Le Lagrangien vaut :  $L(X, \alpha) = Q \bullet X + \frac{\alpha}{2} (n^2 - X \bullet X)$   
 $= \frac{\alpha}{2} n^2 + \frac{\alpha}{2} \left( \frac{Q \bullet Q}{\alpha^2} - \left( X - \frac{Q}{\alpha} \right) \bullet \left( X - \frac{Q}{\alpha} \right) \right)$   
 $= \frac{\alpha}{2} n^2 + \frac{1}{2\alpha} \|Q\|^2 - \frac{\alpha}{2} \left\| X - \frac{Q}{\alpha} \right\|^2$
- Pour  $\alpha < 0$  résoudre le problème dual est NP-difficile (concavité).

# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans (Q) puis dualiser cette dernière contrainte
- $\alpha$  : le multiplicateur de Lagrange associé
- Pour  $\alpha = 0$ , on retrouve la relaxation semidéfinie de base
- Pour  $\alpha \neq 0$  Le Lagrangien vaut :  $L(X, \alpha) = Q \bullet X + \frac{\alpha}{2} (n^2 - X \bullet X)$   
 $= \frac{\alpha}{2} n^2 + \frac{\alpha}{2} \left( \frac{Q \bullet Q}{\alpha^2} - \left( X - \frac{Q}{\alpha} \right) \bullet \left( X - \frac{Q}{\alpha} \right) \right)$   
 $= \frac{\alpha}{2} n^2 + \frac{1}{2\alpha} \|Q\|^2 - \frac{\alpha}{2} \left\| X - \frac{Q}{\alpha} \right\|^2$
- Pour  $\alpha < 0$  résoudre le problème dual est NP-difficile (concavité).
- Pour  $\alpha > 0$  : Soit  $\mathfrak{N} = \{X : Q_i \bullet X \geq 0 \forall i\} \cap \{X \succeq 0, X_{jj} = 1 \forall j\}$ .  
Le programme dual  $\inf_{\alpha} \sup_{X \in \mathfrak{N}} L(X, \alpha)$  est équivalent à un **Problème semidéfini de moindres carrés** : **projection** de  $\frac{Q}{\alpha}$  sur  $\mathfrak{N}$

# Dualiser la Contrainte Sphérique

- **Idée** : remplacer  $X = xx^T$  par  $\|X\|^2 = n^2$  dans  $(Q)$  puis dualiser cette dernière contrainte
- $\alpha$  : le multiplicateur de Lagrange associé
- Pour  $\alpha = 0$ , on retrouve la relaxation semidéfinie de base
- Pour  $\alpha \neq 0$  Le Lagrangien vaut :  $L(X, \alpha) = Q \bullet X + \frac{\alpha}{2} (n^2 - X \bullet X)$   
 $= \frac{\alpha}{2} n^2 + \frac{\alpha}{2} \left( \frac{Q \bullet Q}{\alpha^2} - \left( X - \frac{Q}{\alpha} \right) \bullet \left( X - \frac{Q}{\alpha} \right) \right)$   
 $= \frac{\alpha}{2} n^2 + \frac{1}{2\alpha} \|Q\|^2 - \frac{\alpha}{2} \|X - \frac{Q}{\alpha}\|^2$
- Pour  $\alpha < 0$  résoudre le problème dual est NP-difficile (concavité).
- Pour  $\alpha > 0$  : Soit  $\mathfrak{N} = \{X : Q_i \bullet X \geq 0 \forall i\} \cap \{X \succeq 0, X_{jj} = 1 \forall j\}$ .  
Le programme dual  $\inf_{\alpha} \sup_{X \in \mathfrak{N}} L(X, \alpha)$  est équivalent à un **Problème semidéfini de moindres carrés** : **projection** de  $\frac{Q}{\alpha}$  sur  $\mathfrak{N}$
- La borne obtenue est moins bonne que celle de la PSD standard, mais ces problèmes peuvent être résolus plus efficacement que les PSDs : échange **temps de calcul** contre **qualité de la borne**

# Contrainte Sphérique : un exemple


Pour le problème MAX-CUT :

$$(MC) \begin{cases} \max & Q \bullet X \\ \text{s.c.} & X_{ii} = 1 \\ & X = XX^T \text{ (ou } X \bullet X = n^2) \end{cases} \quad \forall i \in \{1, \dots, n\}$$

On obtient pour  $\alpha > 0$  :

$$(SDPLS(\alpha)) \begin{cases} \min & \|X - \frac{Q}{\alpha}\| \\ \text{s.c.} & X_{ii} = 1 \\ & X \succeq 0 \end{cases} \quad \forall i \in \{1, \dots, n\}$$


# Problème semidéfini de moindres carrés



**Projection** de la matrice  $\frac{Q}{\alpha}$  sur l'intersection du cône des matrices positives et d'un espace affine



# Détériorer la qualité de la borne contre du temps de calcul



Lorsque  $\alpha$  tend vers 0 on retrouve la valeur de la relaxation semidéfinie de base de max-cut