

# Programação semidefinida

João Gouveia



C •

FCTUC FACULDADE DE CIÊNCIAS  
E TECNOLOGIA  
UNIVERSIDADE DE COIMBRA

Jornadas de Matemática - 10 de fevereiro 2018 - Universidade do Porto

# Capítulo 1

## O que é?

# Programação linear - Exemplo

# Programação linear - Exemplo

Um criador de porcos pretende determinar as quantidades de cada tipo de ração que devem ser dadas diariamente a cada animal por forma a conseguir uma certa qualidade nutritiva a um custo mínimo.

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	



# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\min \quad 10x + 5y$$

s. a

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\min \quad 10x + 5y$$

$$\text{s. a} \quad 20x + 50y \geq 200$$



# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\begin{array}{ll} \min & 10x + 5y \\ \text{s. a} & 20x + 50y \geq 200 \\ & 50x + 10y \geq 150 \end{array}$$

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\begin{aligned} \min \quad & 10x + 5y \\ \text{s. a} \quad & 20x + 50y \geq 200 \\ & 50x + 10y \geq 150 \\ & 30x + 30y \leq 600 \end{aligned}$$

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\begin{aligned} \min \quad & 10x + 5y \\ \text{s. a} \quad & 20x + 50y \geq 200 \\ & 50x + 10y \geq 150 \\ & 30x + 30y \leq 600 \\ & x, y \geq 0 \end{aligned}$$

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\begin{aligned} \min \quad & 10x + 5y \\ \text{s. a} \quad & 20x + 50y \geq 200 \\ & 50x + 10y \geq 150 \\ & 30x + 30y \leq 600 \\ & x, y \geq 0 \end{aligned}$$

$$\begin{aligned} \min \quad & 10x + 5y \\ \text{s. a} \quad & \begin{bmatrix} -200 \\ -150 \\ 600 \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} 20 & 50 \\ 50 & 10 \\ -30 & -30 \\ 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \geq 0 \end{aligned}$$

**Forma canónica**

# Programação Linear - Exemplo (cont.)

	Ração A	Ração B	Quantidade Requerida
Proteína	20	50	$\geq 200$
Vitamina	50	10	$\geq 150$
Hid. Carbono	30	30	$\leq 600$
Custo	10	5	

$x \rightarrow$  Quantidade de Ração A       $y \rightarrow$  Quantidade de Ração B.

$$\begin{aligned} \min \quad & 10x + 5y \\ \text{s. a} \quad & 20x + 50y \geq 200 \\ & 50x + 10y \geq 150 \\ & 30x + 30y \leq 600 \\ & x, y \geq 0 \end{aligned}$$

$$\begin{aligned} \min \quad & 10x + 5y \\ \text{s. a} \quad & \begin{bmatrix} 20 & 50 & -1 & 0 & 0 \\ 50 & 10 & 0 & -1 & 0 \\ -30 & -30 & 0 & 0 & -1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z_1 \\ z_2 \\ z_3 \end{bmatrix} = \begin{bmatrix} 200 \\ 150 \\ -600 \end{bmatrix} \\ & x, y, z_1, z_2, z_3 \geq 0 \end{aligned}$$

**Forma normal**

# Programação linear - Definição

## Programa Linear - Forma normal

$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & Ax = b \\ & x \geq 0. \end{array}$$

## Programa Linear - Forma canónica

$$\begin{array}{ll} \min & \langle c, y \rangle \\ \text{s.t.} & b + Ay \geq 0 \end{array}$$

# Programação linear - Definição

## Programa Linear - Forma normal

$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & Ax = b \\ & x \geq 0. \end{array}$$

$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & Ax = b \\ & x \in \mathbb{R}_+^n. \end{array}$$

## Programa Linear - Forma canónica

$$\begin{array}{ll} \min & \langle c, y \rangle \\ \text{s.t.} & b + Ay \geq 0 \end{array}$$

$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & b + Ax \in \mathbb{R}_+^n. \end{array}$$

# Programação linear - Definição

## Programa Linear - Forma normal

$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & Ax = b \\ & x \geq 0. \end{array}$$


$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & Ax = b \\ & x \in \mathbb{R}_+^n. \end{array}$$

## Programa Linear - Forma canónica

$$\begin{array}{ll} \min & \langle c, y \rangle \\ \text{s.t.} & b + Ay \geq 0 \end{array}$$

$$\begin{array}{ll} \min & \langle c, x \rangle \\ \text{s.t.} & b + Ax \in \mathbb{R}_+^n. \end{array}$$

Em ambos os casos estamos a otimizar sobre fatias afins do ortante não-negativo.



Podemos jogar esse jogo com outros cones.



# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.
- $A = \sum_{i=1}^n v_i v_i^t$  para alguns  $v_i \in \mathbb{R}^n$ .

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.
- $A = \sum_{i=1}^n v_i v_i^t$  para alguns  $v_i \in \mathbb{R}^n$ .
- $A = B^t B$  para alguma matriz  $B$ .

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.
- $A = \sum_{i=1}^n v_i v_i^t$  para alguns  $v_i \in \mathbb{R}^n$ .
- $A = B^t B$  para alguma matriz  $B$ .

**Exemplo:**

$$A = \begin{bmatrix} 9 & -8 & -2 \\ -8 & 26 & 4 \\ -2 & 4 & 6 \end{bmatrix} \succeq 0$$

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.
- $A = \sum_{i=1}^n v_i v_i^t$  para alguns  $v_i \in \mathbb{R}^n$ .
- $A = B^t B$  para alguma matriz  $B$ .

**Exemplo:**

$$A = \begin{bmatrix} 9 & -8 & -2 \\ -8 & 26 & 4 \\ -2 & 4 & 6 \end{bmatrix} \succeq 0 \longrightarrow \text{Spec}(A) = \{5, 6, 30\}$$

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.
- $A = \sum_{i=1}^n v_i v_i^t$  para alguns  $v_i \in \mathbb{R}^n$ .
- $A = B^t B$  para alguma matriz  $B$ .

**Exemplo:**

$$A = \begin{bmatrix} 9 & -8 & -2 \\ -8 & 26 & 4 \\ -2 & 4 & 6 \end{bmatrix} \succeq 0 \longrightarrow \text{Spec}(A) = \{5, 6, 30\} \longrightarrow A = \begin{bmatrix} 1 & 2 & 2 \\ 0 & 1 & -5 \\ 2 & -1 & -1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 2 \\ 2 & 1 & -1 \\ 2 & -5 & -1 \end{bmatrix}$$

# O meu cone favorito

Uma matriz  $A$  simétrica  $n \times n$  diz-se semidefinida positiva, e escrevemos  $A \succeq 0$  se

- $x^t A x \geq 0$  para todo  $x \in \mathbb{R}^n$ .
- Os valores próprios de  $A$  forem todos não negativos.
- $A = \sum_{i=1}^n v_i v_i^t$  para alguns  $v_i \in \mathbb{R}^n$ .
- $A = B^t B$  para alguma matriz  $B$ .

**Exemplo:**

$$A = \begin{bmatrix} 9 & -8 & -2 \\ -8 & 26 & 4 \\ -2 & 4 & 6 \end{bmatrix} \succeq 0 \longrightarrow \text{Spec}(A) = \{5, 6, 30\} \longrightarrow A = \begin{bmatrix} 1 & 2 & 2 \\ 0 & 1 & -5 \\ 2 & -1 & -1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 2 \\ 2 & 1 & -1 \\ 2 & -5 & -1 \end{bmatrix}$$

O conjunto das matrizes semidefinidas positivas,  $S_+^n$ , é fechado para adição e multiplicação por escalares positivos: é um *cone convexo*.



## Programa semidefinido - Forma normal

$$\begin{aligned} \min_{X \in \mathcal{S}^n} \quad & \langle C, X \rangle \\ \text{s.t.} \quad & \langle A_i, X \rangle = b_i, \quad i = 1, \dots, m \\ & X \succeq 0. \end{aligned}$$

## Programa semidefinido - Forma canónica

$$\begin{aligned} \min_{y \in \mathbb{R}^m} \quad & \langle c, y \rangle \\ \text{s.t.} \quad & A_0 + \sum y_i A_i \succeq 0 \end{aligned}$$

## Programa semidefinido - Forma normal

$$\begin{aligned} \min_{X \in \mathcal{S}^n} \quad & \langle C, X \rangle \\ \text{s.t.} \quad & \langle A_i, X \rangle = b_i, \quad i = 1, \dots, m \\ & X \succeq 0. \end{aligned}$$

## Programa semidefinido - Forma canónica

$$\begin{aligned} \min_{y \in \mathbb{R}^m} \quad & \langle c, y \rangle \\ \text{s.t.} \quad & A_0 + \sum y_i A_i \succeq 0 \end{aligned}$$


Mais uma vez, em ambos os casos estamos a otimizar sobre fatias afins do cone das matrizes semidefinidas positivas.

# Programação semidefinida - Exemplos

$$\begin{array}{ll} \min & x - y + z \\ \text{s.t.} & \begin{bmatrix} 1 & x & y \\ x & x & z \\ y & z & y \end{bmatrix} \succeq 0 \end{array}$$

# Programação semidefinida - Exemplos


$$\begin{array}{ll} \min & x - y + z \\ \text{s.t.} & \begin{bmatrix} 1 & x & y \\ x & x & z \\ y & z & y \end{bmatrix} \succeq 0 \end{array}$$



# Programação semidefinida - Exemplos


$$\begin{array}{ll} \min & x - y + z \\ \text{s.t.} & \begin{bmatrix} 1 & x & y \\ x & x & z \\ y & z & y \end{bmatrix} \succeq 0 \end{array}$$

$$\begin{array}{ll} \min & x + y + z \\ \text{s.t.} & \begin{bmatrix} 1 + x & y - z & x + y \\ y - z & 1 - x & z \\ x + y & z & z \end{bmatrix} \succeq 0 \end{array}$$




# Programação semidefinida - Exemplos

$$\begin{array}{ll} \min & x - y + z \\ \text{s.t.} & \begin{bmatrix} 1 & x & y \\ x & x & z \\ y & z & y \end{bmatrix} \succeq 0 \end{array}$$



$$\begin{array}{ll} \min & x + y + z \\ \text{s.t.} & \begin{bmatrix} 1 + x & y - z & x + y \\ y - z & 1 - x & z \\ x + y & z & z \end{bmatrix} \succeq 0 \end{array}$$



# Capítulo 2

## Para que serve?

### 1. Problema do corte máximo


## Definition

Dado um grafo  $G = (V, E)$  e uma partição  $V_1, V_2$  de  $V$ , o conjunto  $C$  de arestas entre  $V_1$  e  $V_2$  diz-se um **corte**.



## Definition



Dado um grafo  $G = (V, E)$  e uma partição  $V_1, V_2$  de  $V$ , o conjunto  $C$  de arestas entre  $V_1$  e  $V_2$  diz-se um **corte**.



# Problema do corte máximo

## Definition


Dado um grafo  $G = (V, E)$  e uma partição  $V_1, V_2$  de  $V$ , o conjunto  $C$  de arestas entre  $V_1$  e  $V_2$  diz-se um **corte**.



# Problema do corte máximo

## Definition

Dado um grafo  $G = (V, E)$  e uma partição  $V_1, V_2$  de  $V$ , o conjunto  $C$  de arestas entre  $V_1$  e  $V_2$  diz-se um **corte**.



## O problema

Queremos encontrar o corte  $C$  com o maior número possível de arestas.

# Como encontrar um corte


## Ideia Simples

Lançamos a moeda ao ar para cada vértice e dividimo-los em cara e coroa.

# Como encontrar um corte

## Ideia Simples


Lançamos a moeda ao ar para cada vértice e dividimo-los em cara e coroa.



# Como encontrar um corte

## Ideia Simples


Lançamos a moeda ao ar para cada vértice e dividimo-los em cara e coroa.



# Como encontrar um corte

## Ideia Simples


Lançamos a moeda ao ar para cada vértice e dividimo-los em cara e coroa.



# Como encontrar um corte

## Ideia Simples

Lançamos a moeda ao ar para cada vértice e dividimo-los em cara e coroa.




A probabilidade de uma aresta estar no corte é de  $1/2$ , logo o número médio de arestas obtido é metade das do grafo, e portanto pelo menos metade do corte ótimo.



# Como encontrar um corte

## Ideia Simples

Lançamos a moeda ao ar para cada vértice e dividimo-los em cara e coroa.



A probabilidade de uma aresta estar no corte é de  $1/2$ , logo o número médio de arestas obtido é metade das do grafo, e portanto pelo menos metade do corte ótimo.

**Podemos fazer melhor?**

# Problema reformulado

Seja  $x_i = 1$  se  $i \in V_1$  e  $-1$  se não. Então  $x_i x_j = -1$  se  $\{i, j\}$  estiver no corte e  $1$  se não.

# Problema reformulado

Seja  $x_i = 1$  se  $i \in V_1$  e  $-1$  se não. Então  $x_i x_j = -1$  se  $\{i, j\}$  estiver no corte e  $1$  se não.

## MaxCut

$$\max_{x \in \{-1, 1\}^n} \sum_{i,j} \frac{1}{2} (1 - x_i x_j).$$

# Problema reformulado

Seja  $x_i = 1$  se  $i \in V_1$  e  $-1$  se não. Então  $x_i x_j = -1$  se  $\{i, j\}$  estiver no corte e  $1$  se não.

## MaxCut

$$\max_{x \in \{-1, 1\}^n} \sum_{i, j} \frac{1}{2} (1 - x_i x_j).$$

Note-se que  $X = xx^t = [x_i x_j]_{i, j=1, \dots, n}$ , para  $x \in \{-1, 1\}^n$  se e só se

$$X \succeq 0, X_{ii} = 1 \text{ e } \text{car}(X) = 1.$$

# Problema reformulado

Seja  $x_i = 1$  se  $i \in V_1$  e  $-1$  se não. Então  $x_i x_j = -1$  se  $\{i, j\}$  estiver no corte e  $1$  se não.

## MaxCut

$$\max_{x \in \{-1, 1\}^n} \sum_{i, j} \frac{1}{2} (1 - x_i x_j).$$

Note-se que  $X = x x^t = [x_i x_j]_{i, j=1, \dots, n}$ , para  $x \in \{-1, 1\}^n$  se e só se

$$X \succeq 0, X_{ii} = 1 \text{ e } \text{car}(X) = 1.$$

## MaxCut

$$\max_X \sum_{i, j} \frac{1}{2} (1 - X_{ij}),$$

com  $X \succeq 0$ ,  $\text{diag}(X) = 1$ ,  $\text{car}(X) = 1$ .

# Problema reformulado

Seja  $x_i = 1$  se  $i \in V_1$  e  $-1$  se não. Então  $x_i x_j = -1$  se  $\{i, j\}$  estiver no corte e  $1$  se não.

## MaxCut

$$\max_{x \in \{-1, 1\}^n} \sum_{i,j} \frac{1}{2} (1 - x_i x_j).$$

Note-se que  $X = xx^t = [x_i x_j]_{i,j=1,\dots,n}$ , para  $x \in \{-1, 1\}^n$  se e só se

$$X \succeq 0, X_{ii} = 1 \text{ e } \text{car}(X) = 1.$$


Esquecendo a última condição obtemos uma relaxação.

## MaxCut relaxado

$$\max_X \sum_{i,j} \frac{1}{2} (1 - X_{ij}),$$


com  $X \succeq 0, \text{diag}(X) = 1$

Grafo aleatório com 70 vértices e 250 arestas.



Qual o maior corte?

Grafo aleatório com 70 vértices e 250 arestas.




Qual o maior corte?

No máximo 195, porque o ótimo da relaxação é 195.56



Grafo aleatório com 70 vértices e 250 arestas.



Qual o maior corte?

No máximo 195, porque o ótimo da relaxação é 195.56 **Mas quão boa é a aproximação?**

## Theorem (Goemans-Williamson 95)

*O valor real do MAXCUT é pelo menos 0.87856 vezes o valor da relaxação.*

## Theorem (Goemans-Williamson 95)

*O valor real do MAXCUT é pelo menos 0.87856 vezes o valor da relaxação.*

Como o encontrar?

## Theorem (Goemans-Williamson 95)

*O valor real do MAXCUT é pelo menos 0.87856 vezes o valor da relaxação.*

Como o encontrar?

- 1 Escrever  $X = CC^T$ . Linhas de  $C \leftrightarrow$  vetores em  $\mathbb{R}^n$  de norma 1.

## Theorem (Goemans-Williamson 95)

*O valor real do MAXCUT é pelo menos 0.87856 vezes o valor da relaxação.*

Como o encontrar?

- 1 Escrever  $X = CC^T$ . Linhas de  $C \leftrightarrow$  vetores em  $\mathbb{R}^n$  de norma 1.
- 2 A cada vértice  $v$  de  $G$  corresponde um ponto  $p_v$  na esfera  $S^{n-1}$ .

## Theorem (Goemans-Williamson 95)

*O valor real do MAXCUT é pelo menos 0.87856 vezes o valor da relaxação.*

Como o encontrar?

- 1 Escrever  $X = CC^T$ . Linhas de  $C \leftrightarrow$  vetores em  $\mathbb{R}^n$  de norma 1.
- 2 A cada vértice  $v$  de  $G$  corresponde um ponto  $p_v$  na esfera  $S^{n-1}$ .
- 3 Geramos um hiperplano aleatório e particionamos os vértices conforme o lado em que calham.

## Theorem (Goemans-Williamson 95)

*O valor real do MAXCUT é pelo menos 0.87856 vezes o valor da relaxação.*

Como o encontrar?

- 1 Escrever  $X = CC^T$ . Linhas de  $C \leftrightarrow$  vetores em  $\mathbb{R}^n$  de norma 1.
- 2 A cada vértice  $v$  de  $G$  corresponde um ponto  $p_v$  na esfera  $S^{n-1}$ .
- 3 Geramos um hiperplano aleatório e particionamos os vértices conforme o lado em que calham.

# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?



# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




Probabilidade da aresta  $v, w$  estar no corte é

$$\frac{\theta}{\pi}$$

# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




Probabilidade da aresta  $v, w$  estar no corte é

$$\frac{\theta}{\pi} = \frac{\arccos\langle u, w \rangle}{\pi}$$

# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




Probabilidade da aresta  $v, w$  estar no corte é

$$\frac{\theta}{\pi} = \frac{\arccos\langle u, w \rangle}{\pi} = \frac{\arccos(X_{ij})}{\pi}$$


# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




Probabilidade da aresta  $v, w$  estar no corte é

$$\frac{\theta}{\pi} = \frac{\arccos\langle u, w \rangle}{\pi} = \frac{\arccos(X_{ij})}{\pi}$$




# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?



Probabilidade da aresta  $v, w$  estar no corte é


$$\frac{\theta}{\pi} = \frac{\arccos\langle u, w \rangle}{\pi} = \frac{\arccos(X_{ij})}{\pi}$$






# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?




Probabilidade da aresta  $v, w$  estar no corte é

$$\frac{\theta}{\pi} = \frac{\arccos\langle u, w \rangle}{\pi} = \frac{\arccos(X_{ij})}{\pi} \geq 0.87856 \frac{1 - X_{ij}}{2}.$$




# Porque funciona?

Dados dois vetores  $p_v$  e  $p_w$  qual a probabilidade de  $(v, w)$  estar no corte?



Probabilidade da aresta  $v, w$  estar no corte é


$$\frac{\theta}{\pi} = \frac{\arccos\langle u, w \rangle}{\pi} = \frac{\arccos(X_{ij})}{\pi} \geq 0.87856 \frac{1 - X_{ij}}{2}.$$



O número esperado de arestas é 0.87856 o valor da relaxação.

# Exemplo revisitado


Grafo aleatório com 70 vértices e 250 arestas.



Ótimo da relaxação é 195.56.

# Exemplo revisitado

Grafo aleatório com 70 vértices e 250 arestas.



Ótimo da relaxação é 195.56.

Corte com  $176 > 171.8 = 0.87856 \times 195.56$  arestas

# Capítulo 3

## Para que serve? 2. Otimização polinomial


Dado um polinómio **real**, como verificar se é sempre não negativo?

Dado um polinómio **real**, como verificar se é sempre não negativo?

Será  $x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4$  não negativo?

Dado um polinómio **real**, como verificar se é sempre não negativo?

Será  $x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4$  não negativo?





# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

$$p = \sum_i h_i(x)^2$$

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

$$p = \sum_i h_i(x)^2 = \sum_i (\hat{h}_i^t X_d)^2$$

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

$$p = \sum_i h_i(x)^2 = \sum_i (\hat{h}_i^t X_d)^2 = \sum_i X_d^t h_i \hat{h}_i^t X_d$$

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

$$p = \sum_i h_i(x)^2 = \sum_i (\hat{h}_i^t X_d)^2 = \sum_i X_d^t h_i \hat{h}_i^t X_d = X_d^t \left( \sum_i h_i \hat{h}_i^t \right) X_d$$



# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

$$p = \sum_i h_i(x)^2 = \sum_i (\hat{h}_i^t X_d)^2 = \sum_i X_d^t h_i \hat{h}_i^t X_d = X_d^t \left( \sum_i h_i \hat{h}_i^t \right) X_d = X_d^t H X_d$$

com  $H \succeq 0$ .

# Somas de quadrados

Para certificar não negatividade neste caso basta escrever

$$x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4 = (x^2 - y^2 + y)^2 + (xy - x)^2.$$

- Um polinómio **soma de quadrados** (sdq) é sempre não negativo.
- Mas como verificamos se é sdq?

Seja  $\text{grau}(p) = 2d$  e  $X_d$  o vetor dos monómios de grau  $\leq d$ .

$$p = \sum_i h_i(x)^2 = \sum_i (\hat{h}_i^t X_d)^2 = \sum_i X_d^t h_i \hat{h}_i^t X_d = X_d^t \left( \sum_i h_i \hat{h}_i^t \right) X_d = X_d^t H X_d$$

com  $H \succeq 0$ . Assim  $p$  é sdq se e só se  $p(x) = X_d^t H X_d$  para algum  $H \succeq 0$ .

# Exemplo

$p(\mathbf{x}) = x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4$  tem grau 4 logo  $d = 2$ . Temos:

$$X_2 = [1, x, y, x^2, xy, y^2]^t.$$

# Exemplo

$p(x) = x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4$  tem grau 4 logo  $d = 2$ . Temos:

$$X_2 = [1, x, y, x^2, xy, y^2]^t.$$

$p(x)$  é soma de quadrados sse existir  $H \succeq 0$  tal que

$$p(x) = [1 \quad x \quad y \quad x^2 \quad xy \quad y^2] \begin{bmatrix} h_{11} & h_{12} & h_{13} & h_{14} & h_{15} & h_{16} \\ h_{12} & h_{22} & h_{23} & h_{24} & h_{25} & h_{26} \\ h_{13} & h_{23} & h_{33} & h_{34} & h_{35} & h_{36} \\ h_{14} & h_{24} & h_{34} & h_{44} & h_{45} & h_{46} \\ h_{15} & h_{25} & h_{35} & h_{45} & h_{55} & h_{56} \\ h_{16} & h_{26} & h_{36} & h_{46} & h_{56} & h_{66} \end{bmatrix} \begin{bmatrix} 1 \\ x \\ y \\ x^2 \\ xy \\ y^2 \end{bmatrix}.$$

# Exemplo

$p(x) = x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4$  tem grau 4 logo  $d = 2$ . Temos:

$$X_2 = [1, x, y, x^2, xy, y^2]^t.$$

$p(x)$  é soma de quadrados sse existir  $H \succeq 0$  tal que

$$p(x) = \begin{bmatrix} 1 & x & y & x^2 & xy & y^2 \end{bmatrix} \begin{bmatrix} h_{11} & h_{12} & h_{13} & h_{14} & h_{15} & h_{16} \\ h_{12} & h_{22} & h_{23} & h_{24} & h_{25} & h_{26} \\ h_{13} & h_{23} & h_{33} & h_{34} & h_{35} & h_{36} \\ h_{14} & h_{24} & h_{34} & h_{44} & h_{45} & h_{46} \\ h_{15} & h_{25} & h_{35} & h_{45} & h_{55} & h_{56} \\ h_{16} & h_{26} & h_{36} & h_{46} & h_{56} & h_{66} \end{bmatrix} \begin{bmatrix} 1 \\ x \\ y \\ x^2 \\ xy \\ y^2 \end{bmatrix}.$$

$$p(x) = h_{11} + 2h_{12}x + 2h_{13}y + (2h_{14} + h_{22})x^2 + (2h_{15} + 2h_{23})xy + \dots$$

Expandindo são equações lineares nas entradas de  $H$  logo temos um programa semidefinido que podemos resolver.

# Exemplo

$p(x) = x^2 + x^4 + y^2 - x^2y^2 - 2y^3 + y^4$  tem grau 4 logo  $d = 2$ . Temos:

$$X_2 = [1, x, y, x^2, xy, y^2]^t.$$

$p(x)$  é soma de quadrados sse existir  $H \succeq 0$  tal que

$$p(x) = \begin{bmatrix} 1 & x & y & x^2 & xy & y^2 \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & -1 & 0 \\ 0 & 0 & 1 & 1 & 0 & -1 \\ 0 & 0 & 1 & 1 & 0 & -1 \\ 0 & -1 & 0 & 0 & 1 & 0 \\ 0 & 0 & -1 & -1 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ x \\ y \\ x^2 \\ xy \\ y^2 \end{bmatrix}.$$

$$p(x) = h_{11} + 2h_{12}x + 2h_{13}y + (2h_{14} + h_{22})x^2 + (2h_{15} + 2h_{23})xy + \dots$$

Expandindo são equações lineares nas entradas de  $H$  logo temos um programa semidefinido que podemos resolver.

## Theorem (Hilbert 1888)

*Para polinómios de grau  $2d$  em  $n$  variáveis não negatividade e sdq são equivalentes **se e só se** uma das seguintes condições se verificar:*

## Theorem (Hilbert 1888)

*Para polinómios de grau  $2d$  em  $n$  variáveis não negatividade e sdq são equivalentes **se e só se** uma das seguintes condições se verificar:*

- $n = 1$ ;



## Theorem (Hilbert 1888)

*Para polinómios de grau  $2d$  em  $n$  variáveis não negatividade e sdq são equivalentes **se e só se** uma das seguintes condições se verificar:*

- $n = 1$ ;
- $d = 1$ ;

## Theorem (Hilbert 1888)

*Para polinómios de grau  $2d$  em  $n$  variáveis não negatividade e sdq são equivalentes **se e só se** uma das seguintes condições se verificar:*

- $n = 1$ ;
- $d = 1$ ;
- $n = 2$  and  $d = 2$ .

## Theorem (Hilbert 1888)

Para polinómios de grau  $2d$  em  $n$  variáveis não negatividade e *sdq* são equivalentes **se e só se** uma das seguintes condições se verificar:

- $n = 1$ ;
- $d = 1$ ;
- $n = 2$  and  $d = 2$ .

## Theorem (Artin 1927 - 17.º Problema de Hilbert)

Um polinómio é não negativo **se e só se** for soma de quadrados de funções racionais.

# Exemplo de Motzkin


Em 1967 Motzkin deu o primeiro exemplo explícito de polinómio não negativo não sdq.

$$M(x, y) = x^4y^2 + y^4x^2 + 1 - 3x^2y^2.$$

# Exemplo de Motzkin

Em 1967 Motzkin deu o primeiro exemplo explícito de polinômio não negativo não sdq.


$$M(x, y) = x^4y^2 + y^4x^2 + 1 - 3x^2y^2.$$



# Exemplo de Motzkin

Em 1967 Motzkin deu o primeiro exemplo explícito de polinômio não negativo não sdq.

$$M(x, y) = x^4y^2 + y^4x^2 + 1 - 3x^2y^2.$$



$$M(x, y) = (x^2 + y^2 + 1) \left( \frac{x^3y + xy^3 - 2xy}{x^2 + y^2} \right)^2 + \left( \frac{x^2 - y^2}{x^2 + y^2} \right)^2.$$

Como usar esta ideia na minimização de polinómios?

Como usar esta ideia na minimização de polinómios?

## Otimização polinomial global

$$p_{\min} = \min p(\mathbf{x}) \text{ sobre todo } \mathbf{x} \in \mathbb{R}^n.$$



Como usar esta ideia na minimização de polinómios?

## Otimização polinomial global

$$p_{\min} = \min p(\mathbf{x}) \text{ sobre todo } \mathbf{x} \in \mathbb{R}^n.$$

Transformamos num problema de não negatividade.

## Otimização polinomial global 2.0

$$p_{\min} = \max \lambda \text{ tal que } p(\mathbf{x}) - \lambda \geq 0 \text{ para todo } \mathbf{x} \in \mathbb{R}^n.$$

Como usar esta ideia na minimização de polinómios?

## Otimização polinomial global

$$p_{\min} = \min p(\mathbf{x}) \text{ sobre todo } \mathbf{x} \in \mathbb{R}^n.$$

Transformamos num problema de não negatividade.

## Otimização polinomial global 2.0

$$p_{\min} = \max \lambda \text{ tal que } p(\mathbf{x}) - \lambda \geq 0 \text{ para todo } \mathbf{x} \in \mathbb{R}^n.$$

Agora substituímos a não negatividade.

## Otimização polinomial aproximada

$$p_{\text{sdq}} = \max \lambda \text{ tal que } p(\mathbf{x}) - \lambda \text{ é sdq.}$$

# Otimização

Como usar esta ideia na minimização de polinómios?

## Otimização polinomial global

$$p_{\min} = \min p(\mathbf{x}) \text{ sobre todo } \mathbf{x} \in \mathbb{R}^n.$$

Transformamos num problema de não negatividade.

## Otimização polinomial global 2.0

$$p_{\min} = \max \lambda \text{ tal que } p(\mathbf{x}) - \lambda \geq 0 \text{ para todo } \mathbf{x} \in \mathbb{R}^n.$$

Agora substituímos a não negatividade.

## Otimização polinomial aproximada

$$p_{\text{sdq}} = \max \lambda \text{ tal que } p(\mathbf{x}) - \lambda \text{ é sdq.}$$

Este é um problema semidefinido e dá-nos um minorante para  $p_{\min}$ .

E se quisermos realmente o mínimo e não um minorante?

E se quisermos realmente o mínimo e não um minorante?

## Otimização polinomial aproximada

$$p_{\text{sdq}} = \max \lambda \text{ tal que } p(x) - \lambda \text{ é sdq.}$$

E se quisermos realmente o mínimo e não um minorante?

## Otimização polinomial aproximada

$$p_{\text{sdq}}^k = \max \lambda \text{ tal que } (x_1^2 + x_2^2 + \dots + x_n^2)^k p(x) - \lambda \text{ é sdq.}$$

E se quisermos realmente o mínimo e não um minorante?

## Otimização polinomial aproximada

$$p_{\text{sdq}}^k = \max \lambda \text{ tal que } (x_1^2 + x_2^2 + \dots + x_n^2)^k p(x) - \lambda \text{ é sdq.}$$

Usando geometria algébrica real (Positivstellensatz) podemos provar que

$$\lim_{k \rightarrow \infty} p_{\text{sdq}}^k = p_{\min}$$

E se quisermos realmente o mínimo e não um minorante?

## Otimização polinomial aproximada

$$p_{\text{sdq}}^k = \max \lambda \text{ tal que } (x_1^2 + x_2^2 + \dots + x_n^2)^k p(x) - \lambda \text{ é sdq.}$$

Usando geometria algébrica real (Positivstellensatz) podemos provar que

$$\lim_{k \rightarrow \infty} p_{\text{sdq}}^k = p_{\min}$$

Não é difícil adaptar os métodos para trabalhar com desigualdades e equações polinomiais. Lasserre (2001) e Parrilo (2000) popularizaram esta ideia.



# Obrigado pela vossa atenção

[jgouveia@mat.uc.pt](mailto:jgouveia@mat.uc.pt)