

# **Algoritmos de Aproximação**

**Segundo Semestre de 2012**

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação alternativa:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j)$$

$$\text{sujeito a } x_i^2 = 1 \quad \text{para cada } i \text{ em } V.$$

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação alternativa:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j)$$

$$\text{sujeito a } x_i x_i = 1 \quad \text{para cada } i \text{ em } V.$$

Se  $x$  é solução viável do programa,  $x_i \in \{-1, 1\}$  para todo  $i$ .

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação alternativa:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j)$$

$$\text{sujeito a } x_i x_i = 1 \quad \text{para cada } i \text{ em } V.$$

Se  $x$  é solução viável do programa,  $x_i \in \{-1, 1\}$  para todo  $i$ .

Tome  $S = \{i : x_i = 1\}$ .

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação alternativa:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j)$$

$$\text{sujeito a } x_i x_i = 1 \quad \text{para cada } i \text{ em } V.$$

Se  $x$  é solução viável do programa,  $x_i \in \{-1, 1\}$  para todo  $i$ .

Tome  $S = \{i : x_i = 1\}$ .

Se  $ij \in \delta(S)$  então  $1 - x_i x_j = 2$ , senão  $1 - x_i x_j = 0$ ,

$$\text{logo } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j) = w(\delta(S)).$$

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação alternativa:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j)$$

$$\text{sujeito a } x_i x_i = 1 \quad \text{para cada } i \text{ em } V.$$

Se  $x$  é solução viável do programa,  $x_i \in \{-1, 1\}$  para todo  $i$ .

Tome  $S = \{i : x_i = 1\}$ .

Se  $ij \in \delta(S)$  então  $1 - x_i x_j = 2$ , senão  $1 - x_i x_j = 0$ ,

$$\text{logo } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j) = w(\delta(S)).$$

Se  $\delta(S)$  é corte, seja  $x_i = 1$  se  $i \in S$ ,

e  $x_i = -1$  caso contrário.

# Programação Semidefinida

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação alternativa:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j)$$

$$\text{sujeito a } x_i x_i = 1 \quad \text{para cada } i \text{ em } V.$$

Se  $x$  é solução viável do programa,  $x_i \in \{-1, 1\}$  para todo  $i$ .

Tome  $S = \{i : x_i = 1\}$ .

Se  $ij \in \delta(S)$  então  $1 - x_i x_j = 2$ , senão  $1 - x_i x_j = 0$ ,

$$\text{logo } \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - x_i x_j) = w(\delta(S)).$$

Se  $\delta(S)$  é corte, seja  $x_i = 1$  se  $i \in S$ ,

e  $x_i = -1$  caso contrário. Tal  $x$  é viável de peso  $w(\delta(S))$ .



# Relaxação vetorial

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação quadrática:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij} w_{ij} (1 - x_i x_j)$$

sujeito a  $x_i x_i = 1$  para cada  $i$  em  $V$ .

( $w_{ij} = 0$  se  $ij \notin E$ )

# Relaxação vetorial

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação quadrática:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij} w_{ij} (1 - x_i x_j)$$

sujeito a  $x_i^2 = 1$  para cada  $i$  em  $V$ .

( $w_{ij} = 0$  se  $ij \notin E$ )

**Relaxação vetorial:**

encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que

$$\text{maximize } \frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$$

sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

# Relaxação vetorial

**MAX CUT:** Dados  $G = (V, E)$  e pesos  $w_e \geq 0$  para cada  $e$  em  $E$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação quadrática:** encontrar vetor  $x$  que

$$\text{maximize } \frac{1}{2} \sum_{ij} w_{ij} (1 - x_i x_j)$$

sujeito a  $x_i^2 = 1$  para cada  $i$  em  $V$ .

( $w_{ij} = 0$  se  $ij \notin E$ )

**Relaxação vetorial:**

encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que

$$\text{maximize } \frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$$

sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

As incógnitas são os vetores: **as linhas da matriz  $Y$ .**

# Relaxação vetorial

**MAX CUT:** Dados  $G$  completo e pesos  $w_{ij} \geq 0$  para cada  $ij$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação quadrática:** encontrar vetor  $x$  que  
maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - x_i x_j)$   
sujeito a  $x_i x_i = 1$  para cada  $i$  em  $V$ .

**Relaxação vetorial:**

encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que  
maximize  $\sum_{ij} w_{ij} (1 - (YY^T)_{ij})$   
sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

# Relaxação vetorial

**MAX CUT:** Dados  $G$  completo e pesos  $w_{ij} \geq 0$  para cada  $ij$ , encontrar corte  $\delta(X)$  em  $G$  de peso máximo.

**Formulação quadrática:** encontrar vetor  $x$  que  
maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - x_i x_j)$   
sujeito a  $x_i x_i = 1$  para cada  $i$  em  $V$ .

**Relaxação vetorial:**

encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que  
maximize  $\sum_{ij} w_{ij} (1 - (YY^T)_{ij})$   
sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

**É relaxação:** solução viável  $x$  da formulação quadrática  
corresponde a solução viável do programa vetorial.

(Tome  $Y$  com uma única coluna não nula, dada pelo  $x$ .)

# Relaxação vetorial

Encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que  
maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$   
sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

# Relaxação vetorial

Encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$   
sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

Algumas questões:

- Mas como resolver um programa vetorial?

# Relaxação vetorial

Encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$  sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

Algumas questões:

- Mas como resolver um programa vetorial?
- Aliás, tal programa tem solução?



# Relaxação vetorial

Encontrar matrix real  $Y$   $n \times n$ , onde  $n = |V|$ , que maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$  sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

Algumas questões:

- Mas como resolver um programa vetorial?
- Aliás, tal programa tem solução?
- E o que fazer com a solução depois?

# Tal programa tem solução?

Dados  $G$  e  $w$ , encontrar matrix real  $Y$  que

maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$

sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

# Tal programa tem solução?

Dados  $G$  e  $w$ , encontrar matrix real  $Y$  que

maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$

sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

Seja  $V = V(G)$  e  $n = |V|$ .

Conjunto das soluções viáveis é

subconjunto de  $\mathbb{R}^{n^2}$  **fechado** e **limitado**.

# Tal programa tem solução?

Dados  $G$  e  $w$ , encontrar matrix real  $Y$  que

maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$

sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

Seja  $V = V(G)$  e  $n = |V|$ .

Conjunto das soluções viáveis é

subconjunto de  $\mathbb{R}^{n^2}$  **fechado** e **limitado**.

**Fechado** pois é interseção de hiperplanos.

$((YY^T)_{ii} = 1$  para cada  $i$ )

# Tal programa tem solução?

Dados  $G$  e  $w$ , encontrar matrix real  $Y$  que

maximize  $\frac{1}{2} \sum_{ij} w_{ij} (1 - (YY^T)_{ij})$

sujeito a  $(YY^T)_{ii} = 1$  para cada  $i$  em  $V$ .

Seja  $V = V(G)$  e  $n = |V|$ .

Conjunto das soluções viáveis é

subconjunto de  $\mathbb{R}^{n^2}$  **fechado** e **limitado**.

**Fechado** pois é interseção de hiperplanos.

$((YY^T)_{ii} = 1$  para cada  $i$ )

**Limitado** pois  $\|Y\|^2 = \sum_i Y_{i*} Y_{i*} = \sum_i (YY^T)_{ii} = n$ .

$(Y_{i*}: \text{linha } i \text{ de } Y)$

# O que fazer com sua solução?

Algoritmo de Goemans e Williamson:

MAXCUT-GW  $(G, w)$

- 1 seja  $\hat{Y}$  uma solução ótima do programa vetorial
- 2  $s \leftarrow \text{RANDESFERA}(V(G))$
- 3  $S \leftarrow \{i \in V(G) : s\hat{Y}_{i*} > 0\}$
- 4 **devolva**  $\delta(S)$

# O que fazer com sua solução?

Algoritmo de Goemans e Williamson:

MAXCUT-GW  $(G, w)$

- 1 seja  $\hat{Y}$  uma solução ótima do programa vetorial
- 2  $s \leftarrow \text{RANDESFERA}(V(G))$
- 3  $S \leftarrow \{i \in V(G) : s\hat{Y}_{i*} > 0\}$
- 4 **devolva**  $\delta(S)$

**RANDESFERA**: devolve um  $r$  indexado por  $V(G)$  tq  $\|r\| = 1$   
(ou seja, um ponto na esfera unitária)  
com probabilidade uniforme.

# O que fazer com sua solução?

Algoritmo de Goemans e Williamson:

MAXCUT-GW  $(G, w)$

- 1 seja  $\hat{Y}$  uma solução ótima do programa vetorial
- 2  $s \leftarrow \text{RANDESFERA}(V(G))$
- 3  $S \leftarrow \{i \in V(G) : s\hat{Y}_{i*} > 0\}$
- 4 **devolva**  $\delta(S)$

**RANDESFERA**: devolve um  $r$  indexado por  $V(G)$  tq  $\|r\| = 1$   
(ou seja, um ponto na esfera unitária)  
com probabilidade uniforme.

Cada linha da matriz  $Y$  é um ponto desta mesma esfera.



# Análise

**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

# Análise

**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

Prova: Usemos  $\hat{y}$  e  $\hat{z}$  para denotar  $\hat{Y}_{i^*}$  e  $\hat{Y}_{j^*}$ . Então

# Análise

**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

Prova: Usemos  $\hat{y}$  e  $\hat{z}$  para denotar  $\hat{Y}_{i^*}$  e  $\hat{Y}_{j^*}$ . Então

$$\Pr[ij \in \delta(S)] = \Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] + \Pr[s\hat{y} \leq 0 \text{ e } s\hat{z} > 0].$$

**Termo vermelho:** probabilidade de  $s$  estar na esfera unitária na intersecção dos semi-espacos  $\{r : r\hat{y} > 0\}$  e  $\{r : r\hat{z} \leq 0\}$ .

# Análise


**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

Prova: Usemos  $\hat{y}$  e  $\hat{z}$  para denotar  $\hat{Y}_{i^*}$  e  $\hat{Y}_{j^*}$ . Então

$$\Pr[ij \in \delta(S)] = \Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] + \Pr[s\hat{y} \leq 0 \text{ e } s\hat{z} > 0].$$

**Termo vermelho:** probabilidade de  $s$  estar na esfera unitária na intersecção dos semi-espacos  $\{r : r\hat{y} > 0\}$  e  $\{r : r\hat{z} \leq 0\}$ .

Tal região é a “fatia” da esfera de ângulo igual ao ângulo entre os vetores  $\hat{y}$  e  $\hat{z}$ , que denotamos por  $\Theta$ .



# Análise

**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] = \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

Prova:  $\hat{y}$  e  $\hat{z}$  denotam  $\hat{Y}_{i^*}$  e  $\hat{Y}_{j^*}$  e

$$\Pr[ij \in \delta(S)] = \Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] + \Pr[s\hat{y} \leq 0 \text{ e } s\hat{z} > 0].$$

**Termo vermelho:** probabilidade de  $s$  estar na esfera unitária na intersecção dos semi-espacos  $\{r : r\hat{y} > 0\}$  e  $\{r : r\hat{z} \leq 0\}$ .

# Análise

**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] = \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

Prova:  $\hat{y}$  e  $\hat{z}$  denotam  $\hat{Y}_{i^*}$  e  $\hat{Y}_{j^*}$  e

$$\Pr[ij \in \delta(S)] = \Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] + \Pr[s\hat{y} \leq 0 \text{ e } s\hat{z} > 0].$$

**Termo vermelho:** probabilidade de  $s$  estar na esfera unitária na intersecção dos semi-espacos  $\{r : r\hat{y} > 0\}$  e  $\{r : r\hat{z} \leq 0\}$ .

Pela distribuição uniforme, a probabilidade de tal região é proporcional à área da região, e portanto ao ângulo  $\Theta$ :

$$\Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] = \frac{\Theta}{2\pi}.$$

# Análise

**Lema:** Para  $S$  e  $\hat{Y}$  do algoritmo e quaisquer dois vértices  $i$  e  $j$  de  $G$ ,  $\Pr[ij \in \delta(S)] = \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$ .

Prova:  $\hat{y}$  e  $\hat{z}$  denotam  $\hat{Y}_{i^*}$  e  $\hat{Y}_{j^*}$  e

$$\Pr[ij \in \delta(S)] = \Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] + \Pr[s\hat{y} \leq 0 \text{ e } s\hat{z} > 0].$$

**Termo vermelho:** probabilidade de  $s$  estar na esfera unitária na intersecção dos semi-espacos  $\{r : r\hat{y} > 0\}$  e  $\{r : r\hat{z} \leq 0\}$ .

Pela distribuição uniforme, a probabilidade de tal região é proporcional à área da região, e portanto ao ângulo  $\Theta$ :

$$\Pr[s\hat{y} > 0 \text{ e } s\hat{z} \leq 0] = \frac{\Theta}{2\pi}.$$

Do mesmo modo,  $\Pr[s\hat{y} \leq 0 \text{ e } s\hat{z} > 0] = \Theta/2\pi$ , o que termina a prova, já que  $\Theta = \arccos(\hat{y}\hat{z})$ .

# O que falta para concluir?

Seja  $W$  o valor da solução produzida por MAXCUT-GW.



# O que falta para concluir?

Seja  $W$  o valor da solução produzida por MAXCUT-GW.

Lembre-se que, por linearidade da esperança,

$$E[W] = \sum_{ij} w_{ij} \Pr[ij \in \delta(S)].$$

# O que falta para concluir?

Seja  $W$  o valor da solução produzida por MAXCUT-GW.

Lembre-se que, por linearidade da esperança,

$$E[W] = \sum_{ij} w_{ij} \Pr[ij \in \delta(S)].$$

Pelo lema então

$$E[W] = \frac{1}{\pi} \sum_{ij} w_{ij} \arccos((\hat{Y}\hat{Y}^T)_{ij}).$$

# O que falta para concluir?

Seja  $W$  o valor da solução produzida por MAXCUT-GW.

Lembre-se que, por linearidade da esperança,

$$E[W] = \sum_{ij} w_{ij} \Pr[ij \in \delta(S)].$$

Pelo lema então

$$E[W] = \frac{1}{\pi} \sum_{ij} w_{ij} \arccos((\hat{Y}\hat{Y}^T)_{ij}).$$

Vamos ver, na aula que vem, que

$$E[W] \geq 0,878 \sum_{ij} w_{ij} (1 - (\hat{Y}\hat{Y}^T)_{ij}) \geq 0,878 \text{OPT}.$$