

Algoritmos de Aproximação

Segundo Semestre de 2012

Cobertura por conjuntos

Instância:

- conjunto base finito E
- coleção $\mathcal{S} = \{S_1, \dots, S_m\}$ de subconjuntos de E
- custo $c_j > 0$ para cada S_j em \mathcal{S}

Objetivo: encontrar cobertura $\mathcal{S}' \subseteq \mathcal{S}$ de E de custo mínimo.

Cobertura por conjuntos

Instância:

- conjunto base finito E
- coleção $\mathcal{S} = \{S_1, \dots, S_m\}$ de subconjuntos de E
- custo $c_j > 0$ para cada S_j em \mathcal{S}

Objetivo: encontrar cobertura $\mathcal{S}' \subseteq \mathcal{S}$ de E de custo mínimo.

Programa linear inteiro equivalente:

Dados E , \mathcal{S} e c , encontrar x que

minimize $\sum_j c_j x_j$

sujeito a $\sum_{j:e \in S_j} x_j \geq 1$ para cada e em E

$x_j \in \{0, 1\}$ para $j = 1, \dots, m$.

Relaxação linear e seu dual

Primal: Dados E , S e c , encontrar x que

$$\text{minimize } \sum_j c_j x_j$$

$$\text{sujeito a } \sum_{j:e \in S_j} x_j \geq 1 \text{ para cada } e \text{ em } E$$

$$x_j \geq 0 \text{ para } j = 1, \dots, m$$

Relaxação linear e seu dual

Primal: Dados E , S e c , encontrar x que

$$\text{minimize } \sum_j c_j x_j$$

$$\text{sujeito a } \sum_{j:e \in S_j} x_j \geq 1 \text{ para cada } e \text{ em } E$$

$$x_j \geq 0 \text{ para } j = 1, \dots, m$$

Dual: Dados E , S e c , encontrar y que

$$\text{maximize } \sum_e y_e$$

$$\text{sujeito a } \sum_{e \in S_j} y_e \leq c_j \text{ para } j = 1, \dots, m$$

$$y_e \geq 0 \text{ para cada } e \in E$$

Relaxação linear e seu dual

Primal: Dados E , S e c , encontrar x que

$$\text{minimize } \sum_j c_j x_j$$

$$\text{sujeito a } \sum_{j:e \in S_j} x_j \geq 1 \text{ para cada } e \text{ em } E$$

$$x_j \geq 0 \text{ para } j = 1, \dots, m$$

Dual: Dados E , S e c , encontrar y que

$$\text{maximize } \sum_e y_e$$

$$\text{sujeito a } \sum_{e \in S_j} y_e \leq c_j \text{ para } j = 1, \dots, m$$

$$y_e \geq 0 \text{ para cada } e \in E$$

Teorema Fraco de Dualidade: Quaisquer que sejam x primal-viável e y dual-viável, vale que $\sum_e y_e \leq \sum_j c_j x_j$.

Relaxação linear e seu dual

Primal: Dados E , S e c , encontrar x que

$$\text{minimize } \sum_j c_j x_j$$

$$\text{sujeito a } \sum_{j:e \in S_j} x_j \geq 1 \text{ para cada } e \text{ em } E$$

$$x_j \geq 0 \text{ para } j = 1, \dots, m$$

Dual: Dados E , S e c , encontrar y que

$$\text{maximize } \sum_e y_e$$

$$\text{sujeito a } \sum_{e \in S_j} y_e \leq c_j \text{ para } j = 1, \dots, m$$

$$y_e \geq 0 \text{ para cada } e \in E$$

Teorema Forte de Dualidade: Se x^* é solução ótima do primal e y^* é solução ótima do dual, então

$$\sum_e y_e^* = \sum_j c_j x_j^*.$$

Algoritmo guloso

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

- 1 $I \leftarrow \emptyset$
- 2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$
- 3 **enquanto** I não é uma cobertura **faça**
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
- 6 **para** $j \leftarrow 1$ **até** m **faça**
- 7 $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$
- 8 **devolva** I

Algoritmo guloso

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

- 1 $I \leftarrow \emptyset$
- 2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$
- 3 **enquanto** I não é uma cobertura **faça**
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
- 6 **para** $j \leftarrow 1$ **até** m **faça**
- 7 $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$
- 8 **devolva** I

Consumo de tempo polinomial, sem resolução de PL!

Algoritmo guloso

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

- 1 $I \leftarrow \emptyset$
- 2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$
- 3 **enquanto** I não é uma cobertura **faça**
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
- 6 **para** $j \leftarrow 1$ **até** m **faça**
- 7 $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$
- 8 **devolva** I

Consumo de tempo polinomial, sem resolução de PL!

Claro que I é uma cobertura.

Algoritmo guloso

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

- 1 $I \leftarrow \emptyset$
- 2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$
- 3 **enquanto** I não é uma cobertura **faça**
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
- 6 **para** $j \leftarrow 1$ **até** m **faça**
- 7 $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$
- 8 **devolva** I

Consumo de tempo polinomial, sem resolução de PL!

Claro que I é uma cobertura.

Teorema: **GULOSO** é uma H_n -aproximação, onde $n = |E|$.

Prova feita na aula.

Análise pelo método dual-fitting

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

- 1 $I \leftarrow \emptyset$
- 2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$
- 3 **enquanto** I não é uma cobertura **faça**
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
- 6 **para** $j \leftarrow 1$ **até** m **faça**
- 7 $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$
- 8 **devolva** I

Claro que I é uma cobertura.

Teorema: **GULOSO** é uma H_g -aproximação, onde $g = \max_j |S_j|$.

A prova usa o método dual-fitting...

Análise pelo método dual-fitting

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

1 $I \leftarrow \emptyset$

2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$

3 **enquanto** I não é uma cobertura **faça**

4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$

5 $I \leftarrow I \cup \{k\}$

\triangleright **para cada** e **em** \hat{S}_k **faça** $y_e \leftarrow c_k / |\hat{S}_k|$

6 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$

7 **devolva** I

Teo: **GULOSO** é uma H_g -aproximação, onde $g = \max_j |S_j|$.

Análise pelo método dual-fitting

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

1 $I \leftarrow \emptyset$

2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$

3 **enquanto** I não é uma cobertura **faça**

4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$

5 $I \leftarrow I \cup \{k\}$

\triangleright **para cada** e **em** \hat{S}_k **faça** $y_e \leftarrow c_k / |\hat{S}_k|$

6 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$

7 **devolva** I

Teo: **GULOSO** é uma H_g -aproximação, onde $g = \max_j |S_j|$.

Prova: Note que $c(I) = \sum_{k \in I} c_k = \sum_{e \in E} y_e$.

Análise pelo método dual-fitting

GULOSO (E, \mathcal{S}, c) $\triangleright \mathcal{S} = \{S_1, \dots, S_m\}$

1 $I \leftarrow \emptyset$

2 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow S_j$

3 **enquanto** I não é uma cobertura **faça**

4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$

5 $I \leftarrow I \cup \{k\}$

\triangleright **para cada** e **em** \hat{S}_k **faça** $y_e \leftarrow c_k / |\hat{S}_k|$

6 **para** $j \leftarrow 1$ **até** m **faça** $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$

7 **devolva** I

Teo: **GULOSO** é uma H_g -aproximação, onde $g = \max_j |S_j|$.

Prova: Note que $c(I) = \sum_{k \in I} c_k = \sum_{e \in E} y_e$.

Para cada e em E , defina $y'_e = y_e / H_g$.

Vamos mostrar que $\sum_{e \in S_j} y'_e \leq c_j$ para cada j .

Análise pelo método dual-fitting

- 3 enquanto I não é uma cobertura faça
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
 ▷ para cada e em \hat{S}_k faça $y_e \leftarrow c_k / |\hat{S}_k|$
- 6 para $j \leftarrow 1$ até m faça $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$

Teo: GULOSO é uma H_g -aproximação, onde $g = \max_j |S_j|$.

Prova: Note que $c(I) = \sum_{k \in I} c_k = \sum_{e \in E} y_e$.

Para cada e em E , defina $y'_e = y_e / H_g$.

Se $\sum_{e \in S_j} y'_e \leq c_j$ para cada j , então y' é dual-viável e

Análise pelo método dual-fitting

- 3 enquanto I não é uma cobertura faça
- 4 $k \leftarrow \arg \min \left\{ \frac{c_j}{|\hat{S}_j|} : j \text{ é tal que } \hat{S}_j \neq \emptyset \right\}$
- 5 $I \leftarrow I \cup \{k\}$
 ▷ para cada e em \hat{S}_k faça $y_e \leftarrow c_k / |\hat{S}_k|$
- 6 para $j \leftarrow 1$ até m faça $\hat{S}_j \leftarrow \hat{S}_j \setminus S_k$

Teo: GULOSO é uma H_g -aproximação, onde $g = \max_j |S_j|$.

Prova: Note que $c(I) = \sum_{k \in I} c_k = \sum_{e \in E} y_e$.

Para cada e em E , defina $y'_e = y_e / H_g$.

Se $\sum_{e \in S_j} y'_e \leq c_j$ para cada j , então y' é dual-viável e

$$c(I) = \sum_{k \in I} c_k = \sum_{e \in E} y_e = H_g \sum_{e \in E} y'_e \leq H_g \text{ opt.}$$

Análise pelo método dual-fitting

Fix j , com $1 \leq j \leq m$, e seja $a_i = |\hat{S}_j|$ no início da iteração i .

Análise pelo método dual-fitting

Fix j , com $1 \leq j \leq m$, e seja $a_i = |\hat{S}_j|$ no início da iteração i .

Seja $A_i = \hat{S}_j \cup \hat{S}_k$ na linha 5 da iteração i
(ou seja, A_i são os elementos de S_j cobertos na iteração i).

Análise pelo método dual-fitting

Fix j , com $1 \leq j \leq m$, e seja $a_i = |\hat{S}_j|$ no início da iteração i .

Seja $A_i = \hat{S}_j \cup \hat{S}_k$ na linha 5 da iteração i
(ou seja, A_i são os elementos de S_j cobertos na iteração i).

Note que $|A_i| = a_i - a_{i+1}$.

Análise pelo método dual-fitting

Fix j , com $1 \leq j \leq m$, e seja $a_i = |\hat{S}_j|$ no início da iteração i .

Seja $A_i = \hat{S}_j \cup \hat{S}_k$ na linha 5 da iteração i
(ou seja, A_i são os elementos de S_j cobertos na iteração i).

Note que $|A_i| = a_i - a_{i+1}$.

Seja t a última iteração em que $a_i > 0$. Então

$$\sum_{e \in S_j} y'_e = \sum_{i=1}^t \sum_{e \in A_i} y'_e \leq \sum_{i=1}^t |A_i| \frac{c_j}{a_i},$$

onde a desigualdade vale pois o k que entrou em I na iteração i tem custo médio mínimo, e j é um dos candidatos a entrar em I e tem custo médio c_j/a_i na iteração i .

Análise pelo método dual-fitting

Fix j , com $1 \leq j \leq m$, e seja $a_i = |\hat{S}_j|$ no início da iteração i .

Seja $A_i = \hat{S}_j \cup \hat{S}_k$ na linha 5 da iteração i
(ou seja, A_i são os elementos de S_j cobertos na iteração i).

Note que $|A_i| = a_i - a_{i+1}$.

Seja t a última iteração em que $a_i > 0$. Então

$$\begin{aligned} \sum_{e \in S_j} y'_e &= \sum_{i=1}^t \sum_{e \in A_i} y'_e \leq \sum_{i=1}^t |A_i| \frac{c_j}{H_g a_i} \\ &= \frac{c_j}{H_g} \sum_{i=1}^t \frac{a_i - a_{i+1}}{a_i} \leq \frac{c_j}{H_g} \sum_{i=1}^t \frac{|S_j|}{i} \\ &= \frac{c_j H_{|S_j|}}{H_g} \leq c_j, \quad \text{pois } g = \max_j |S_j|. \end{aligned}$$

Resultados de inaproximabilidade

Teorema: Se existe uma $b \ln n$ -aproximação para o SET COVER para alguma constante $b < 1$, então existe um algoritmo $O(n^{O(\lg \lg n)})$ para cada problema NP-completo.

Resultados de inaproximabilidade

Teorema: Se existe uma $b \ln n$ -aproximação para o SET COVER para alguma constante $b < 1$, então existe um algoritmo $O(n^{O(\lg \lg n)})$ para cada problema NP-completo.

Teorema: Existe uma constante $b > 0$ tal que, se existir uma $b \ln n$ -aproximação para o SET COVER, então $P = NP$.

Resultados de inaproximabilidade

Teorema: Se existe uma $b \ln n$ -aproximação para o SET COVER para alguma constante $b < 1$, então existe um algoritmo $O(n^{O(\lg \lg n)})$ para cada problema NP-completo.

Teorema: Existe uma constante $b > 0$ tal que, se existir uma $b \ln n$ -aproximação para o SET COVER, então $P = NP$.

Estes dois resultados valem para o caso sem pesos (ou seja, $c_j = 1$ para todo j).

Resultados de inaproximabilidade

Teorema: Se existe uma α -aproximação para o VERTEX COVER com $\alpha < 10\sqrt{5} - 21 \approx 1,36$, então $P = NP$.

Resultados de inaproximabilidade

Teorema: Se existe uma α -aproximação para o VERTEX COVER com $\alpha < 10\sqrt{5} - 21 \approx 1,36$, então $P = NP$.

A conjectura do *Unique Games* fala que um certo problema conhecido como *Unique Games* é NP-difícil.

Teorema: Assumindo a conjectura do Unique Games, se existe uma α -aproximação para o VERTEX COVER para uma constante $\alpha < 2$, então $P = NP$.