



Approximationsalgorithmen

Facility Location K-Median

Cheng, Wei
12. Juli



The background is a traditional Chinese ink wash painting on a light yellowish-green paper. It features several stylized pine trees with green needles and dark brown trunks. In the upper right corner, three birds are depicted in flight, rendered with simple black ink strokes. The overall style is minimalist and elegant.

Facility Location

Definition

Gegeben:

- mögliche Standorte $F = \{F_1, F_2 \dots F_m\}$
- Städte $C = \{C_1, C_2 \dots C_n\}$
- Eröffnungskosten f_i für F_i
- Verbindungskosten c_{ij} zwischen F_i und C_j
 - ◎ *Dreiecksungleichung*

Definition

Gesucht:

- Eröffne Teilmenge $I \subseteq F$ von Standorten
- Funktion $\phi : C \rightarrow I$
 - ⊙ verbinde jede Stadt mit offenem Standort.
- Gesamtkosten minimieren
 - ⊙ Eröffnungskosten der Standorte
 - ⊙ Verbindungskosten zwischen Stadt und Standort

Primales/ Duales LP

Primal:

Minimiere:

$$\sum_{i \in F, j \in C} c_{ij} x_{ij} + \sum_{i \in F} f_i y_i$$

Nebenbedingungen:

$$\begin{aligned} \sum_{i \in F} x_{ij} &\geq 1 & , & & j \in C \\ y_i - x_{ij} &\geq 0 & , & & i \in F, j \in C \\ x_{ij} &\geq 0 & , & & i \in F, j \in C \\ y_i &\geq 0 & , & & i \in F \end{aligned}$$

Dual:

Maximiere:

$$\sum_{j \in C} \alpha_j$$

Nebenbedingungen:

$$\begin{aligned} \alpha_j - \beta_{ij} &\leq c_{ij} & , & & i \in F, j \in C \\ \sum_{j \in C} \beta_{ij} &\leq f_i & , & & i \in F \\ \alpha_j &\geq 0 & , & & j \in C \\ \beta_{ij} &\geq 0 & , & & i \in F, j \in C \end{aligned}$$

Verwandte Arbeiten

- Hochbaum [1982] $O(\log n)$
- Shmoys, Tardos and Aardal [1998] 3,16
- Jain and Vazirani [2001] 3
- Mahdian, Ye and Zhang [2004] 1,52

- Guha and Khuller [1998]
untere Schranke 1,463

Primal-Dual basierter Algorithmus

- Phase 1

- ⊙ Öffnen mehrere Standorte, und verbinden alle Städte mit Standorten. (Eine Stadt kann mit mehr einem Standort verbinden.)

- Phase 2

- ⊙ Schließen unnötige Standorte, und verbinden alle Städte mit nur einem Standort.

Algorithmus (Phase 1)

- Am Anfang
 - ⊙ Zeit 0
 - ⊙ Alle Städte sind *unverbunden*
 - ⊙ Alle Variablen = 0

Algorithmus (Phase 1)

- Erhöhe α_j der *unverbundenen* Städte j um 1
- Wenn $\alpha_j = c_{ij}$ von Kante, ist Kante (i,j) *bezahlt*.
=> Duale Variable β_{ij} wird erhöht, laut $\alpha_j - \beta_{ij} \leq c_{ij}$.
- β_{ij} bezahlt Eröffnungskosten f_i für F_i
 - ⊙ Kanten (i, j) mit $\beta_{ij} > 0$ heißen *besonders*.
- Wenn $\sum_j \beta_{ij} = f_i$, ist Standort i *bezahlt*.
 - ⊙ Standort i ist *temporär geöffnet*.

Algorithmus (Phase 1)

- Stadt mit *bezahlter* Kante zu eröffnetem Standort F_i ist *verbunden*.
- Standort i ist *Verbindungszeuge* dieser Städte.
- α_j *verbundener* Städte werden nicht mehr erhöht.
- Sobald *unverbundene* Stadt j *bezahlte* Kante zu eröffnetem Standort i hat:
 - ⊙ Stadt j ebenfalls *verbunden*.
 - ⊙ Standort i ist *Verbindungszeuge* von j .
 - ⊙ **Achtung**: Hier ist $\beta_{ij} = 0$, und Kante (i, j) *unbesonders*.

Algorithmus (Phase 1)

- Phase 1 endet, wenn alle Städte *verbunden*.
- Eine Stadt zu mehreren Standorten verbunden.
- Zu viele Standorte geöffnet.

Primal-Dual basierter Algorithmus

● Phase 1

- ⊙ Öffnen mehrere Standorte, und verbinden alle Städte mit Standorten. (Eine Stadt kann mit mehr einem Standort verbinden.)

● Phase 2


- ⊙ Schließen unnötige Standorte, und verbinden alle Städte mit nur einem Standort.

Algorithmus (Phase 2)

- F_t – *temporär geöffnete Standorte*
- T – durch *besondere Kanten* induzierter Teilgraph
- T^2 – $\forall (u, v) \in T \Rightarrow (u, v) \in T^2$
 $\forall (u, v) \in T \wedge (v, w) \in T \Rightarrow (u, w) \in T^2$
- H – von F_t induzierter Graph in T^2

Algorithmus (Phase 2)

- Wähle I als *Maximal Independent Set* in H
- **Maximum** Independent Set (NP-schwer)
- **Maximal** Independent Set:
einfacher Greedy-Algorithmus
- Alle Standorte in I werden geöffnet.



Algorithmus (Phase 2)

- $F_j = \{i \in F_t \mid \beta_{ij} > 0\}$, für jede Stadt j
- I independent set \Rightarrow höchstens ein Standort in F_j geöffnet.
- Fall 1: Ein Standort $i \in F_j$ ist *geöffnet*.
 - ⊙ $\Phi(j) = i$, und Stadt j ist *direkt verbunden*.
- Fall 2: Alle Standorte in F_j sind *ungeöffnet*.

Algorithmus (Phase 2)

- Fall 2: Alle Standorte in F_j sind *ungeöffnet*.
Betrachte bezahlte Kante (i',j) , $\beta_{i'j} = 0$
 i' ist *Verbindungszeuge* von j
 - ◎ Fall 2.1: $i' \in I$
 - ◎ Stadt j ist *direkt verbunden*. $\Phi(j) = i'$
 - ◎ Achtung: **Bis jetzt ist die Lösung Optimal.**
 - ◎ Fall 2.2: $i' \notin I$
 - ◎ i eröffneter Nachbar von i' in Graph H .
 - ◎ $\Phi(j) = i$, und Stadt j ist *indirekt verbunden*.

Algorithmus (Phase 2)

- (I, Φ) ist Lösung.
- $x_{ij} = 1 \Leftrightarrow \Phi(j) = i$
- $y_i = 1 \Leftrightarrow i \in I$

Analyse

- Definition: $\alpha_j = \alpha_j^f + \alpha_j^e$
- *j* indirekt verbunden
 - ⊙ $\alpha_j^f = 0$ $\alpha_j^e = \alpha_j$
- *j* direkt verbunden
 - ⊙ $\alpha_j^f = \beta_{ij}$ $\alpha_j^e = c_{ij}$ für $\Phi(j) = i$

Analyse

● Lemma 1: $\sum_{j:\Phi(j)=i} \alpha_j^f = f_i$

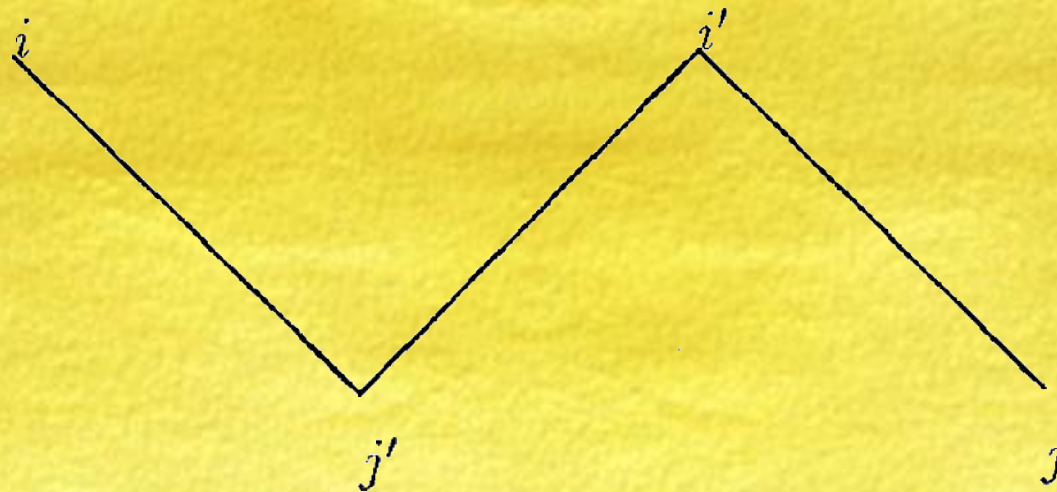
● Folgerung 2: $\sum_{j \in C} \alpha_j^f = \sum_{i \in I} f_i$

● Lemma 3: Für eine *indirekt verbunden* Stadt j :

$$c_{ij} \leq 3\alpha_j^e \quad i = \Phi(j)$$

Analyse

- i' Verbindungszeuge von Stadt j
- j verbindet *indirekt* zu $i \Rightarrow (i, i') \in H$
- (i, j') und (i', j') sind beide *besondere* Kanten.



Analyse

● Satz 4:
$$\sum_{i \in F, j \in C} c_{ij} x_{ij} + 3 \sum_{i \in F} f_i y_i \leq 3 \sum_{j \in C} \alpha_j$$

● Beweis:

⊙ $c_{ij} \leq 3\alpha_j^e$ (Lemma 3) $\Rightarrow \sum_{i \in F, j \in C} c_{ij} x_{ij} \leq 3 \sum_{j \in C} \alpha_j^e$

⊙ $\sum_{j \in C} \alpha_j^f = \sum_{i \in I} f_i$

Zusammenfassung

- Implementierung mit Priority Queue
- Jede Kante wird max. 2-mal betrachtet.
 - ⊙ *bezahlt*
 - ⊙ *verbunden*
- Der Algorithmus berechnet in $O(m \log m)$ Zeit eine 3-Approximation für Facility Location.

K-Median



Definition

Gegeben:

- Eröffnungskosten $f_i = 0$ für F_i
- max. K Standorte eröffnen

Gesucht:

- Gesamtkosten minimieren

Primales/ Duales LP

Primal:

Minimieren:

$$\sum_{i \in F, j \in C} c_{ij} x_{ij}$$

Nebenbedingungen:

$$\begin{aligned} \sum_{i \in F} x_{ij} &\geq 1 & , & & j \in C \\ y_i - x_{ij} &\geq 0 & , & & i \in F, j \in C \\ \sum_{i \in F} -y_i &\geq -k & , & & \\ x_{ij} &\geq 0 & , & & i \in F, j \in C \\ y_i &\geq 0 & , & & i \in F \end{aligned}$$

Dual:

Maximieren:

$$\sum_{j \in C} \alpha_j - zk$$

Nebenbedingungen:

$$\begin{aligned} \alpha_j - \beta_{ij} &\leq c_{ij} & , & & i \in F, j \in C \\ \sum_{j \in C} \beta_{ij} &\leq z & , & & i \in F \\ \alpha_j &\geq 0 & , & & j \in C \\ \beta_{ij} &\geq 0 & , & & i \in F, j \in C \\ z &\geq 0 & , & & \end{aligned}$$

Verwandte Arbeiten

- Bartal [1998] $O(\log n \log \log n)$
 - Charikar [1999] $6+2/3$
 - Jain and Vazirani [2001] 6
 - Arya [2002] $3+2/p$
- Laufzeit $O(n^p)$

Grundidee

- z : Eröffnungskosten eines Standorts
- Suchen **geeignetes z** , benutzen anschließend Algorithmus für Facility Location.

- Wir suchen $\sum_{i \in F} y_i = k$

Grundidee

- $z = 0 \Rightarrow$ alle Standorte werden geöffnet.
- z sehr groß \Rightarrow nur ein Standort wird geöffnet.
- $z \in [0, nc_{\max}]$
- Finde z mit binärer Suche.

Grundidee

● z_1 und z_2 $z_1 - z_2 \leq c_{\min} / (12n_c^2)$

● Finden entspricht $k_1 < k$ und $k_2 > k$

⊙ (x^s, y^s) $\sum_{i \in F} y_i^s = k_1$

⊙ (x^l, y^l) $\sum_{i \in F} y_i^l = k_2$

● $(x, y) = a (x^s, y^s) + b (x^l, y^l)$

$$k = a k_1 + b k_2$$

$$a = (k_2 - k) / (k_2 - k_1) \quad b = (k - k_1) / (k_2 - k_1)$$


Lemma 5

- Die Kosten von (x, y) sind höchstens $(3 + 1/n_c)$ mal so groß wie die einer optimalen (nicht notwendig ganzzahligen) Lösung des K-Median Problems .

- Beweisskizze:


$$\sum_{i \in F, j \in C} c_{ij} x_{ij} \leq \left(3 + \frac{1}{n_c} \right) \left(\sum_{j \in C} \alpha_j - z_1 k \right)$$

Randomisiertes Runden



Randomisiertes Runden

- Mit Wahrscheinlichkeit a werden alle Standorte in A geöffnet. Mit $b = 1-a$, alle Standorte in B' .
- Außerdem $k-k_1$ Standorte in $B-B'$ werden zufällig geöffnet.
- I ist Menge der geöffneten Standorte, $|I| = k$.



Randomisiertes Runden

- Definiere $\Phi : C \rightarrow I$:

für Stadt j , $i_1 \in A$ $i_2 \in B$


- Fall 1: $i_2 \in B' \Rightarrow$ verbinde zu vorhandenem Standort

- Fall 2: $i_2 \in B - B'$

- $i_3 \in B'$ ist nächster Standort von i_1

- Verbinde zu i_1 oder i_2 oder i_3

- $\text{cost}(j) = ac_{i_1 j} + bc_{i_2 j}$



Randomisiertes Runden

- Lemma 6: erwartete Kosten von Stadt j

$$E[c_{\Phi(j)j}] \leq (1 + \max(a, b)) \text{cost}(j)$$

- Fall 1: $E[c_{\Phi(j)j}] = \text{cost}(j) = ac_{i_1j} + bc_{i_2j}$

- Fall 2:

- i_2 geöffnet : wahrscheinlichkeit

b

- i_2 nicht geöffnet und i_1 geöffnet :

$(1-b)a = a^2$

- beide nicht öffnet:

$(1-b)(1-a) = ab$

- $E[c_{\Phi(j)j}] \leq bc_{i_2j} + a^2c_{i_1j} + abc_{i_3j}$

Approximation

- $E \left[\sum_{i \in F, j \in C} c_{ij} x_{ij}^k \right] \leq (1 + \max(a, b)) \left(\sum_{i \in F, j \in C} c_{ij} x_{ij} \right)$

- $a \leq 1 - 1/n_c$ ($k_1 = k - 1$ und $k_2 = n_c$)

- $b \leq 1 - 1/k$ ($k_1 = 1$ und $k_2 = k + 1$)

- $(1 + \max(a, b)) \leq 2 - 1/n_c$

- Approximationsgarantie ist $(2 - 1/n_c)(3 + 1/n_c) < 6$

Laufzeit

- Binäre Suche in $[0, nc_{\max}]$ bis $z_1 - z_2 \leq c_{\min} / (12n_c^2)$
- $O(\log(c_{\max} / c_{\min}) + \log n)$ Proben
- Gesamtlaufzeit $O(m \log m (\log(c_{\max} / c_{\min}) + \log n))$

Zusammenfassung

- Der Algorithmus berechnet in $O(m \log m)$ Zeit eine 3-Approximation für Facility Location.
- Unser Algorithmus berechnet in $O(m \log m (\log(c_{\max} / c_{\min}) + \log n))$ Zeit eine 6-Approximation für K-Median.

Vielen Dank!

