

5.1 Max Cardinality Graph Matching

Problème :

Input Stream: Arêtes d'un graphe à n sommets (n connu) dans un ordre arbitraire.
Exemple : $(2, 3), (1, 4), (5, 2), \dots$

Output: Couplage M de plus grande taille possible.

Mémoire : $O(n \times \text{polylog}(n)) = O(n \times \log^{O(1)}(n))$

Définition 5.1. M est une C -approximation de Max Cardinality Graph Matching si $|M| \geq C \times |M^*|$ où M^* est un couplage de plus grande taille du graphe.

Théorème 5.2. Il existe un algorithme déterministe à 1 passe, de mémoire $O(n \log n)$ qui renvoie une $\frac{1}{2}$ -approximation de Max Cardinality Graph Matching.

Théorème 5.3. (2012) Il n'existe pas d'algorithme en 1 passe et mémoire $O(n \times \text{polylog}(n))$ qui retourne mieux qu'une $\frac{2}{3}$ -approximation (même probabiliste).

Théorème 5.4. (2013) *Idem* : pas mieux qu'une $(1 - 1/e)$ -approximation.

Remarque : Cette borne reste vraie dans le modèle "vertex arrival order".

ALGORITHME GLOUTON

$M \leftarrow \emptyset$

Tant que Stream non vide

$e \leftarrow$ lire arête du Stream

 Si $M \cup \{e\}$ est encore un couplage

$M \leftarrow M \cup \{e\}$

Retourner M

Mémoire : $O(n \log n)$ car $|M| \leq \frac{n}{2}$.

Lemme 5.5. M est maximal pour l'inclusion.

C'est à dire que $\forall e \in G$:

- Soit $e \in M$
- Soit $M \cup \{e\}$ n'est pas un couplage.

Preuve: Vrai par construction de M .

On prouve par induction qu'à chaque instant, M est maximal pour les arêtes déjà lues. \square

Lemme 5.6. Soit M^* un couplage de plus grande taille. Soit M un couplage maximal pour l'inclusion. Alors

$$|M| > \frac{1}{2}|M^*|$$

Notations On note M^* un couplage de plus grande taille du graphe G .

Pour M couplage quelconque, on note $V(M)$ l'ensemble des sommets couverts par M .

Preuve: (Par charge)

- 1) Chaque arête de M^* reçoit une charge.
- 2) Chaque arête de M^* transmet cette charge sur une de ses extrémités dans $V(M)$.

Remarque : C'est toujours possible car pour une arête $e = (a, b) \in M^*$, si ni a , ni b ne sont dans $V(M)$, alors $M \cup \{e\}$ est encore un couplage (absurde par maximalité de M).

On a par définition :

$$\sum_{v \in V(M)} \text{charge}(v) = |M^*|$$


De plus, comme M^* est un couplage, chaque sommet reçoit au plus 1 charge. On en conclut que :

$$|M^*| = \sum_{v \in V(M)} \text{charge}(v) \leq |V(M)| = \frac{1}{2}|M|$$

\square


La combinaison des deux lemmes précédents prouve le **Théorème 5.2**.

Exemple: G tel que l'algorithme glouton qui ne donne pas mieux qu'une $\frac{1}{2}$ -approximation.
 $n = 4$



5.2 Matching in "vertex arrival order"

Input: Graphe biparti sur n sommets.



Stream: $j \in R$ "arrive" avec la liste des sommets avec qui j est connecté.

Exemple: $(1, \underline{1}), (3, \underline{1}), (17, \underline{1}), (4, \underline{2}), (3, \underline{2}), (17, \underline{3}), (1, \underline{3}), \dots$

Théorème 5.7. *Il existe un algorithme probabiliste en 1 passe de mémoire en $O(n \log n)$ qui calcule un couplage M tel que :*

$$\mathbb{E}[|M|] \geq (1 - \frac{1}{e})|M^*|$$

(où l'espérance porte sur les choix probabilistes de l'algorithme.)

Motivation : "adwords" (online)

L : advertisers

R : key words

Modèle simple: $(i, j) \in G$ si i veut bien payer pour le mot clef j .
 i paye au plus une fois.

Les mots clefs "arrivent" (stream), il faut choisir à la volée quelle publicité afficher pour maximiser son gain. On n'affiche qu'une publicité par mot clef.

Modèle plus complexe: i veut bien payer V_i par mot clef.

Modèle adwords: i a en plus un budget B_i et veut bien payer $V_{i,j}$ pour le mot clef j .

Remarque : Tout ces problèmes dérivent du précédent.

Remarque : Pour une détermination "online", on ne peut pas faire mieux qu'une $\frac{1}{2}$ -approximation avec l'algorithme précédent.

ALGORITHME RANKING

Pour tout $i \in L$

 Choisir au hasard un réel $Y_i \in [0, 1]$

$M \leftarrow \emptyset$

Tant que Stream non vide

$j \leftarrow$ lire sommet du Stream (et ses arêtes)

 Trouver i parmi les voisins de j tel que $i \notin V(M)$ et Y_i minimal.

 Si on trouve un tel i

$M \leftarrow M \cup \{(i, j)\}$

Retourner M

5.2.1 Analyse de 2013

Programmation linéaire pour un couplage de taille maximale.

Intuition: $x_{i,j} = 1$ si $(i, j) \in M$, 0 sinon.

$$\text{Opt} = \max \sum_{(i,j) \in E} x_{i,j}$$

Contraintes:

$$\forall i \in L, \sum_{j|(i,j) \in E} x_{i,j} \leq 1$$

$$\forall j \in R, \sum_{i|(i,j) \in E} x_{i,j} \leq 1$$

$$\forall i \in L, \forall j \in R, x_{i,j} \geq 0$$



La solution maximale n'est pas nécessairement entière.

Lemme 5.8. $\text{Opt}(G) \geq |M^*|$

Écriture du dual.

Minimisation:

$$\text{Opt} = \min \sum_{i \in L} \alpha_i + \sum_{j \in R} \beta_j$$

Contraintes:

$$\forall i \in L, \alpha_i \geq 0$$

$$\forall j \in R, \beta_j \geq 0$$

$$\forall (i, j) \in E, \alpha_i + \beta_j \geq 1$$

On va montrer que l'algorithme de ranking peut nous fournir une solution $(\alpha_i)_{i \in L}, (\beta_j)_{j \in R}$ qui vérifie les propriétés suivantes :

Propriété 1 : $\bar{\alpha}_i = \mathbb{E}(\alpha_i), \bar{\beta}_j = \mathbb{E}(\beta_j)$ vérifient les contraintes du dual.

Propriété 2 : $|M| = \left(\sum_{i \in L} \alpha_i + \sum_{j \in R} \beta_j \right) \cdot \left(1 - \frac{1}{e} \right)$

Preuve: (Théorème 5.7)

D'après la première propriété

$$\sum_{i \in L} \bar{\alpha}_i + \sum_{j \in R} \bar{\beta}_j \geq \text{Opt}(G) \geq |M^*|$$

D'après la seconde :

$$\mathbb{E}[|M|] = \left(1 - \frac{1}{e} \right) \left(\sum_{i \in L} \bar{\alpha}_i + \sum_{j \in R} \bar{\beta}_j \right)$$

On en conclut

$$\mathbb{E}[|M|] \geq \left(1 - \frac{1}{e} \right) \cdot |M^*|$$

□

Construction des α_i, β_j :

Soient $g : [0, 1] \rightarrow [0, 1]$ et $F \in [0, 1]$.

Dans la pratique, on verra qu'il faut choisir $g(y) = e^{y-1}$ et $F = \left(1 - \frac{1}{e} \right)$.

Lorsque i est couplé avec j par l'algorithme, on pose :

$$\begin{aligned} \alpha_i &= \frac{1}{F} g(Y_i) \\ \beta_j &= \frac{1}{F} (1 - g(Y_i)) \end{aligned}$$

Pour i non couplé, on pose $\alpha_i = 0$.

Pour j non couplé, on pose $\beta_j = 0$.

Intuition : i a un budget $\frac{1}{F}$ et il paye une fraction $(1 - g(Y_i))$ à j .

Preuve: Montrons (α_i, β_j) solution de la **Propriété 2**.

Pour chaque arête $(i, j) \in M$, $\alpha_i + \beta_j = F$ et si $i \notin V(M)$, $\alpha_i = 0$ et si $j \notin V(M)$, $\beta_j = 0$.

Donc :

$$\left(\sum_{i \in L} \alpha_i + \sum_{j \in R} \beta_j \right) = \frac{1}{F} \cdot |M|$$

□

Preuve: Montrons la **Propriété 2**.

La seule chose à vérifier est :

$$\forall (i, j) \in E, \quad \mathbb{E}[\alpha_i] + \mathbb{E}[\beta_j] \geq 1 \quad (5.1)$$

Fixons (i, j) et notons $Y^{-i} = (Y_k)_{k \neq i}$.

On va montrer (5.1) lorsque uniquement Y_i est aléatoire.

Considérons l'algorithme sur G privé de i .

- Si j est couplé avec i' , posons $v = Y_{i'}$ et $\beta_j^{-i} = \frac{1-g(v)}{F}$.
- Si j n'est pas couplé, posons $v = 1$.

Lemme 5.9. (*non prouvé*)

1. Si $Y_i < v$ alors i est couplé avec quelqu'un.
2. On a toujours $\beta_j \geq \beta_j^{-i}$.

Conséquences :

$$\begin{aligned} \mathbb{E}_{Y_i}(\beta_j) &\geq \beta_j^{-i} = \frac{1-g(v)}{F} \\ \mathbb{E}_{Y_i}(\alpha_i) &\geq \int_0^v \frac{g(y)}{F} dy \\ \mathbb{E}_{Y_i}(\alpha_i + \beta_j) &= \frac{1}{F} \left[1 - g(v) + \int_0^v g(y) dy \right] \end{aligned}$$

- Si on pose $g(v) = e^{v-1}$, il faut choisir

$$F \leq 1 - e^{v-1} + \left(e^{v-1} - \frac{1}{e} \right) = 1 - \frac{1}{e}$$

- Si on pose $g(v) = v$, il faut choisir

$$F \leq 1 - v + \frac{v^2}{2}$$

pour tout v donc $F \leq \frac{1}{2}$.

□

5.3 Correction des exercices

5.3.1 Exercice 1

Input: Stream de n entiers dans $[1, n]$ avec exactement un doublon α (β manquant).

Output: Trouver α .

Contraintes: Mémoire en $O(n \log n)$, une passe.

ALGORITHME SOLUTION

Calculer en une passe :

$$\begin{aligned} - S_1 &= \sum_{i=1}^n a_i \\ - S_2 &= \sum_{i=1}^n a_i^2 \end{aligned}$$

On a :

$$\begin{aligned} S_1 &= \frac{n(n+1)}{2} + \alpha - \beta \\ S_2 &= \frac{n(n+1)(2n+1)}{6} + \alpha^2 - \beta^2 \end{aligned}$$

Retourner l'unique (car $\alpha \neq \beta$) solution du système.
