

4.1 Préliminaires

4.1.1 Algorithme d'approximation

Problème d'optimisation :

- **Input** : muni d'une fonction cost
- **Output** : qui minimise ou maximise la fonction cost. Cette valeur est appelée *valeur optimum* (OPT).

Exemple 1. (Cardinality) Vertex Cover

- **Input** : Graphe non-orienté $G = (V, E)$.
- **Output** : Ensemble $S \subseteq V$ de plus petite taille tel que $\forall e \in E, e \cap S \neq \emptyset$

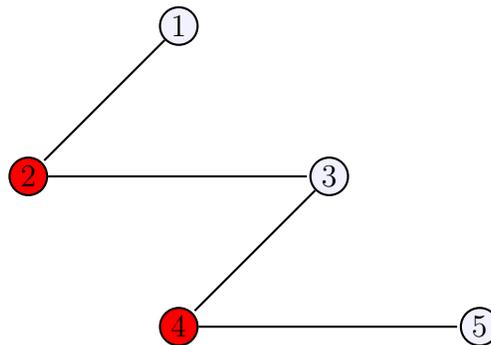


Figure 4.1. Exemple de vertex cover symbolisé en rouge.

Pour un graphe étoilé par rapport à $u \in V$, $S = \{u\}$ convient et $|\text{Opt}| = 1$.

Pour un graphe complet, on a : $|\text{Opt}| = |V| - 1, \forall v \in V, V - \{v\}$ convient.

Dans le cas d'une ligne de taille $2n$, $|\text{Opt}| = n$.

Définition 4.1. Soit $\alpha \geq 1$. A est un algorithme qui calcule une α -approximation d'un problème P si pour toute entrée x :

- Max : $\text{cost}(A(x)) \leq \text{cost}(\text{Opt}(x)) \leq \alpha \text{cost}(A(x))$
- Min : $\text{cost}(\text{Opt}(x)) \leq \text{cost}(A(x)) \leq \alpha \text{cost}(\text{Opt}(x))$

On peut généraliser aux algorithmes probabilistes Las Vegas ou Monte Carlo. α est appelé le facteur (ou ratio) d'approximation.

Retour sur l'exemple

Algorithme. Calculer un couplage M maximal pour l'inclusion (algorithme glouton linéaire). Renvoyer $S = V(M)$ où $V(M)$ est l'ensemble des sommets composant les arêtes de M .

Proposition 4.1.2. *Cette algorithme est une 2-approximation de Vertex Cover.*

Preuve: S est un set cover par maximalité de M . Montrons que : $|S| \leq 2|\text{Opt}|$

On montre en fait que $|\text{Opt}| \leq |M|$. En effet, comme Opt est vertex cover, à toute arête de M correspond un noeud différent de Opt . De plus, $2|M| = |S|$ nous donne bien le résultat. \square

4.1.3 La méthode probabiliste

Le principe de cette méthode est que, afin de montrer que quelque chose existe, on montre qu'il existe avec une probabilité non nulle.

Théorème 4.2. *Si $\binom{n}{k} < 2^{\binom{k}{2}-1}$, alors il est possible de colorier les arêtes du graphe complet K_n à n sommets avec deux couleurs, tel qu'il n'y ait pas de clique K_k monochrome.*

Exemple 2. *Si on fait le calcul avec $n = 1000$ et $k = 20$, on a le résultat.*

Preuve: On définit une fonction $\text{Color} : \{1, 2, \dots, n\} \rightarrow \{0, 1\}$ de manière probabiliste par chaque arête de $e \in \binom{n}{2}$ est coloriée uniformément au hasard.

Numérotons toutes les k -cliques de 1 à $\binom{n}{k}$.

$$A_i := \Pr[\text{La } i\text{-ème clique est monochromatique}] = \frac{1}{2}^{\binom{k}{2}-1}$$

$$\text{On a : } \Pr[\text{Aucune clique est monochromatique}] = 1 - \Pr[\exists i, A_i] = 1 - \Pr\left[\bigcup_i A_i\right].$$

$$\text{Or, } \Pr\left[\bigcup_i A_i\right] \leq \sum_i \Pr(A_i) = \binom{n}{k} \frac{1}{2}^{\binom{k}{2}-1}.$$

D'après l'hypothèse sur n et k , on a bien $\Pr[\text{Aucune clique est monochromatique}] > 0$. \square

4.2 Argument par linéarité de l'espérance

Principe 1. *Soit S un espace probabiliste, X une variable aléatoire définie sur S telle que $\mathbf{E}(X) = \mu$. Alors, $\Pr(X \geq \mu) > 0$ et $\Pr(X \leq \mu) > 0$ et il existe une instance de S pour laquelle $X \geq \mu$.*

Définition 4.3. $G = (V, E)$ un graphe non-orienté. Une cut de G est une partition de V en deux parties $(S, V \setminus S)$.

Problème :

- **Input** : $G = (V, E)$
- **Output** : Cut maximal

Résoudre ce problème est utile en physique statistique, en circuit design (connaître le nombre minimal de superpositions de fils par exemple...).

Théorème 4.4. *Il existe une cut S de taille plus grande que $\frac{|E|}{2} \geq \frac{|\text{Opt}|}{2}$.*

Preuve: Pour chaque sommet v , on décide uniformément, aléatoirement et indépendamment si $v \in S$. Pour chaque arête, on définit $X_e = \mathbf{1}_{e \in S \times V \setminus S}$.

Donc $\text{Taille}(S) = \sum_{e \in E} X_e = \text{Cut}(S)$. On a alors,

$$\mathbf{E}(\text{Cut}(S)) = \sum_{e \in E} \mathbf{E}(X_e) = \sum_{e=\{u,v\} \in E} \Pr((u \in S, v \notin S) \text{ ou } (u \notin S, v \in S)) = \frac{|E|}{2}$$

□

D'après le principe énoncé au début, on dispose de S tel que : $\text{cut}(S) \geq \frac{|E|}{2}$.

Corollaire 4.5. *Il existe un algorithme probabiliste qui calcule en moyenne une 2-approximation de cut maximal en temps $O(|V|)$.*

Corollaire 4.6. *Il existe un algorithme déterministe qui calcule en moyenne une 2-approximation de cut maximal en temps $O(|V||E|)$.*

Preuve: La preuve du premier corollaire est facile, on tire simplement au hasard chaque sommet pour S .

Soit $V = \{1, 2, \dots, n\}$.

$$\mathbf{E}(\text{cut}(S)) = \frac{1}{2} \mathbf{E}_{S|1 \in S}(\text{cut}(S)) + \frac{1}{2} \mathbf{E}_{S|1 \notin S}(\text{cut}(S)) \geq \frac{|E|}{2}$$

Ainsi, nécessairement l'un des deux termes de la somme est forcément supérieur à $\frac{|E|}{2}$

De manière générale, on sait calculer $\mathbf{E}(\text{cut}(S) | A \subset S, B \cap S = \emptyset) = \sum_{e \in E} \underbrace{\mathbf{E}(X_e | A \subset S, B \cap S = \emptyset)}_{=0, 1 \text{ ou } \frac{1}{2}}$

La dérandomization consiste à calculer successivement les espérances conditionnelles (conditionnées aux choix préalablement faits), en s'assurant de toujours rester supérieur à l'espérance initiale. □

Problème du Max-SAT

- **Input** : $\varphi = C_1 \wedge C_2 \wedge \dots \wedge C_m$
- **Output** : $a \in \{0, 1\}^n$ qui maximise le nombre de clauses satisfaites

Théorème 4.7. *Max 2SAT est NP-difficile.*

Théorème 4.8. *Il existe un algorithme probabiliste qui calcule une 2-approximation de Max SAT en moyenne.*

Lemme 4.9. *Pour une clause C à k variables (non-dégénérée), on a $\Pr(C(a) = 1) = 1 - 2^{-k}$.*

Preuve (du lemme): Soit $C = X_{i_1} \vee X_{i_2} \vee \dots \vee X_{i_k}$. Cette clause est satisfaite si sa négation ne l'est pas. Comme les i_j sont distincts (C est non-dégénérée), on dénombre un seul n -uplet qui convient, d'où le résultat. \square

Preuve (du théorème): On construit un algorithme qui renvoie $a \in \{0, 1\}^n$ uniformément choisi au hasard. On appelle Z_C la variable aléatoire définie par $Z_C = \mathbf{1}_{C(a)=1}$. Le nombre de clauses satisfaites par s'écrit alors $A = \sum_{C \in \varphi} Z_C$.

$$\mathbf{E} \left(\sum_{C \in \varphi} Z_C \right) = \sum_{C \in \varphi} \mathbf{E}(Z_C) \geq \underbrace{\frac{1}{2}}_{\text{cas } k=1} \times n \geq \frac{n}{2}$$

\square

Observation 1. *Si chaque clause a exactement k variable, on a une $\frac{1}{1 - 2^{-k}}$ -approximation.*

Observation 2. *De la même façon que précédemment on peut dérandomizer.*

4.3 Echantillonnage et modification

Max indépendant set

Définition 4.10. $G = (V, E)$, $S \subset V$ est indépendant si $E \cap (S \times S) = \emptyset$.

- **Input** : G
- **Output** : Ensemble indépendant S de taille maximale

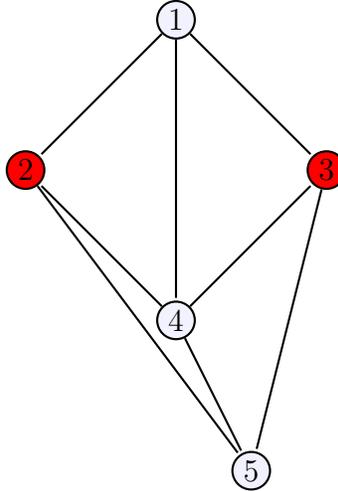


Figure 4.2. Exemple de set indépendant symbolisé en rouge.

Algorithme. $n = |V|, m = |E|$.

1. $d = \frac{2m}{n}$
2. Pour chaque noeud $v \in V$. Supprimer v avec une probabilité $1 - \frac{1}{d}$ (et toutes les arêtes incidentes).
3. Pour chaque arête restante, la supprimer ainsi qu'un de ses sommets choisis aléatoirement.
4. Renvoyez S l'ensemble des sommets restants.

Théorème 4.11. S est un ensemble indépendant de G , $\mathbf{E}(S) \geq \frac{n^2}{2m}$.

Preuve: $X = \#\{\text{noeuds survivants après 1.}\}$. $\mathbf{E}(X) = \frac{n}{d} = \frac{n^2}{2m}$.

$Y = \#\{\text{arêtes survivantes après 1.}\}$. $\mathbf{E}(Y) = \frac{m}{d^2} = \frac{n^2}{4m}$.

$|S| \geq |X| - |Y| = \frac{n^2}{4m}$. □