

# Schémas d'approximation et simulation.

[Chap 10 des Mitzenmacher-Uptal  
Probability and computing]

## (a) $(\epsilon, \delta)$ approximation.

P un problème qui a une solution de valeur  $V$   
A un algorithme qui renvoie  $x$ , une variable aléatoire.

OSES: A est une  $(\epsilon, \delta)$  approximation pour la valeur  $V$  si:  
 $P(|x - V| \leq \epsilon V) \geq 1 - \delta$ .

Exemple: approximation de  $\pi$ .



On place  $m$  points au hasard uniformément sur le cercle, indép.  
 $Z_i = \begin{cases} 1 & \text{si le } i\text{-ième pt est dans le cercle} \\ 0 & \text{sinon.} \end{cases}$  :  $P(Z_i = 1) = \frac{\pi}{4}$ .

$Z_1, \dots, Z_m$  iid,  $\sim \text{Ber}(\pi/4)$ . Soit  $Z = \sum_{i=1}^m Z_i$  :  $E[Z] = \frac{m\pi}{4}$ .  $w = \frac{4}{m} Z$  ( $E[w] = \pi$ )

Borne de Chernoff ( $\epsilon < 1$ )  $P(|w - \pi| \geq \epsilon \pi) = P(|Z - \frac{m\pi}{4}| \geq \frac{\epsilon m \pi}{4}) \leq 2 e^{-\frac{m \pi \epsilon^2}{12}}$

Pour avoir une  $(\epsilon, \delta)$  approx, il faut que  $2 e^{-\frac{m \pi \epsilon^2}{12}} \leq \delta$  et donc  $m \geq \frac{12 \ln(2/\delta)}{\pi \epsilon^2}$

## (b) Schéma d'approximation polynomial

P un problème  $x$  entrée  $P(x)$  la solution pour cette entrée  
A un algorithme  $x$  entrée  $A(x)$  la v.a. renvoyée par l'algo pour cette entrée.

FPRAS: fully polynomial randomized approximation scheme pour un pb P  
est un algo aléatoire A par lequel  $\forall \epsilon, \delta, 0 < \epsilon, \delta < 1, \forall x$  entrée  
 $A(x)$  est une  $(\epsilon, \delta)$ -approx de  $V(x)$  et se calcule en un tps polynomial  
en  $1/\epsilon, 1/\delta$  et la taille de  $x$ .

lemme utile: Si  $X_1, \dots, X_m$  iid,  $E(X_i) = \mu$ . Si  $m \geq \frac{3 \ln(2/\delta)}{\epsilon^2 \mu}$  alors  
 $P(|\frac{1}{m} \sum X_i - \mu| \geq \epsilon \mu) \leq \delta$ .

Application au pb de couplage

Ex: formule en DNF (forme normale disjonctive)  $F = C_1 \vee C_2 \vee \dots \vee C_k$ .  $C_i = x_1 \wedge \dots$

Problème: combien d'affectations des variables satis font  $F$ ?

Le problème de décision associé est: existe-t-il une affectation des variables qui satisfait  $F$ ?

$\rightarrow$  problème facile: il suffit qu'une clause soit satisfiable et donc qu'une clause ne soit pas contradictoire.

Le problème difficile qui est associé est: CNF (forme normale conjonctive) qui est NP-complet  $\rightarrow$  le problème de couplage associé à CNF est aussi difficile.

Mais alors le pb de couplage par DNF est facile:

CNF  $\rightarrow$  DNF  
 $H \mapsto \bar{H}$  en utilisant les lois de De Morgan

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (x_2 \wedge \bar{x}_4) \vee \dots \longleftarrow (\bar{x}_1 \vee x_2 \vee \bar{x}_3) \wedge (\bar{x}_2 \vee x_4)$$

Classe de complexité #P:  $\exists$  DT non det en tps polynomial tel que  $\forall$  entrée  $x$ , le nb de ch. acceptants est le nb de solutions. (2)

Plus pratiquement: il existe un algorithme (déterministe) qui vérifie qu'une instance de #P est solution en tps polynomial.

Si  $A$  est un #P alors #A est le pb de compter le nb de instances qui ont solutions de ce problème.

Autres exemples de pb de comptage artificiels

- nb de complexes parfaits (alors que le pb de décision est facile)
- nb de ch. Hamiltoniens

Algorithme naïf #DNF entrée: Formule  $F$

$X \leftarrow 0$

Pour  $k$  allant de 1 à  $m$  faire

- générer une affectation des variables de manière uniforme
- si cette affectation satisfait  $F$  alors  $X \leftarrow X+1$

Retourner  $Y \leftarrow \frac{X}{m} 2^m$ .

On note  $c(F)$  le nombre d'affectations qui satisfont  $F$ .

$$\text{On a } E(Y) = \frac{2^E(X)}{m} = c(F). \quad (E(X) = \frac{\overbrace{\# \text{ch. sat } x^m}^{c(F)}}{2^m})$$

→ pour avoir une  $(\epsilon, \delta)$  approx, il faut  $m \geq \frac{3 \cdot 2^m}{\epsilon^2 c(F)} \ln(\frac{2}{\delta})$  ↳ exponentiel en la taille de l'entrée.

Algo FPRAS pour #DNF.

$F = C_1 \vee C_2 \vee \dots \vee C_t$ . On suppose qu'aucune clause ne contient  $x_i$  et  $\neg x_i$  (sinon on peut éliminer cette clause).

• Si  $C_i$  a  $l_i$  littéraux alors exactement  $2^{m-l_i}$  affectations satisfont  $C_i$ .

• On note  $S C_i = \{x \mid F(x) = 1\}$  et  $U = \{C_i(x) \mid 1 \leq i \leq t, x \in S C_i\}$

$$|S C_i| = 2^{m-l_i}, \quad \sum_{i=1}^t |S C_i| = |U| \quad \text{et} \quad c(F) = |\bigcup_{i=1}^t S C_i|. \quad [c(F) \leq |U|]$$

Soit  $S = \{C_i(x) \mid 0 \leq i \leq t, x \in S C_i, x \notin S C_j \forall j < i\}$ .

[pour chaque  $x$  tel  $F(x) = 1$ , on prend la t<sup>ème</sup> clause qui est satisfaite unigt.]

Donc  $|S| = c(F)$ .

$|U|$  est connu, donc on peut estimer  $c(F)$  en estimant  $\frac{|S|}{|U|}$ .

et comme  $\frac{|S|}{|U|} \geq \frac{1}{t}$ ,  $S$  est a priori incluse dans  $U$  que l'ens. des solutions dans l'ensemble des affectations.

Algo: FPRAS pour #DNF

$X \leftarrow 0$

• choisir  $i$  avec proba  $\frac{|S C_i|}{\sum_{j=1}^t |S C_j|} = \frac{|S C_i|}{|U|}$

• choisir  $x$  au hasard dans  $S C_i$  ( $l_i$  variables fixés, les autres au hasard)

• si  $\exists j < i, x \notin S C_j$  alors  $X \leftarrow X+1$

• Retourner  $Y = \left(\frac{X}{m}\right) \sum_{i=1}^t |S C_i|$

On vérifie bien que  $P(c_i, x) = P(c_i, P_{i-1}(x)) P(x, P_{i-1}(c_i))$  (3)

$$= \frac{|SC_i|}{|U|} \times \frac{1}{|SC_i|} = \frac{1}{|U|}$$

donc  $E(Y) = \frac{E(X)}{m} \sum |SC_i| = \frac{m \cdot c(F)}{\sum |SC_i|} \times \sum |SC_i| = c(F)$ .

De plus, on peut choisir  $m = \lceil \frac{3}{\epsilon^2} \ln(\frac{2}{\delta}) \rceil$  car  $E(X) \geq \frac{m}{\epsilon}$ .

© Lien entre échantillonnage et approximation des comptages.

Déf. Un échantillonneur  $\epsilon$ -uniforme est un algorithme qui génère  $w \in \Omega$  tel que

$$\forall S \subseteq \Omega \quad \left| P(w \in S) - \frac{|S|}{|\Omega|} \right| \leq \epsilon$$

(Lien direct avec la existence de randomisation).

FPAUS: Fully polynomial almost uniform sampler pour  $\Omega$  est un algo qui prend en entrée  $\epsilon > 0$ , il génère un échantillon  $\epsilon$ -uniforme de  $\Omega(x)$  et s'exécute en temps polynomial en  $\ln(1/\epsilon)$  et en la taille de  $\Omega$ .

But: transformer un FPAUS en un FPRAS.

Exemple: dénombrer les indépendants d'un graphe.

$G = (V, E)$  graphe non-orienté  
 $E = \{e_1, \dots, e_m\}$   $G_m = G$ ,  $G_{i-1} = G_i - \{e_i\}$   
 $\Omega(G_i) \hat{=} \{ \text{indépendants de } G_i \}$

[comme dans l'exemple préc, on ne peut pas utiliser une méthode naïve:  $2^m$  sous-ensembles de sommets].

$$G_m: |\Omega(G)| = \frac{|\Omega(G_m)|}{|\Omega(G_{m-1})|} \times \frac{|\Omega(G_{m-1})|}{|\Omega(G_{m-2})|} \times \dots \times \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \times \frac{|\Omega(G_0)|}{|\Omega(G_0)|} = 2^m$$

On cherche à estimer  $r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}$ . Si  $\tilde{r}_i$  est un estimateur der. alors  $|\Omega(G)|$  est estimé par  $2^m \prod \tilde{r}_i = \tilde{R}$ .

L'erreur est de  $R = \prod_{i=1}^m \frac{\tilde{r}_i}{r_i}$ .

On veut obtenir  $P(|\tilde{R} - |\Omega(G)|| \leq \epsilon |\Omega(G)|) = P\left(\left| \frac{\tilde{R}}{|\Omega(G)|} - 1 \right| \leq \epsilon\right) = P(|R - 1| \leq \epsilon) \geq 1 - \delta$ .

Lemme: si  $\tilde{r}_i$  est une  $(\frac{\epsilon}{2m}, \delta/m)$ -approximation der. alors  $P(|R - 1| \leq \epsilon) \geq 1 - \delta$ .

Dém. On se propose que  $\forall i, P(|\tilde{r}_i - r_i| \leq \frac{\epsilon}{2m} r_i) \geq 1 - \delta/m$ . Donc  $P(|\tilde{r}_i - r_i| \geq \frac{\epsilon}{2m} r_i) \leq \delta/m$ .

Union bound:  $P(\exists i: |\tilde{r}_i - r_i| \geq \frac{\epsilon}{2m} r_i) \leq \delta$  et donc  $P(\forall i: |\tilde{r}_i - r_i| \leq \frac{\epsilon}{2m} r_i) \geq 1 - \delta$ .

$$\begin{aligned} \text{Or } P(\forall i: |\tilde{r}_i - r_i| \leq \frac{\epsilon}{2m} r_i) &\leq P\left(\left(1 - \frac{\epsilon}{2m}\right)^m \leq \prod \frac{\tilde{r}_i}{r_i} \leq \left(1 + \frac{\epsilon}{2m}\right)^m\right) \\ &\leq P\left(1 - \epsilon \leq \prod \frac{\tilde{r}_i}{r_i} \leq 1 + \epsilon\right) \\ &\quad \underbrace{\prod \frac{\tilde{r}_i}{r_i}}_R \end{aligned}$$

Donc  $P(|R - 1| \leq \epsilon) \geq 1 - \delta$ .

Algorithme: estimer  $r_i$  (on suppose que l'on dispose d'un FPAUS pour les indépendants).

Entrée:  $G_{i-1} = (V, E_{i-1})$ ,  $G_i = (V, E_i)$

Sortie:  $\tilde{r}_i$

$X \leftarrow 0$

Répéter  $n = \lceil \frac{3 \ln(2/\delta)}{\epsilon^2} m^2 \ln(2m/\delta) \rceil$  fois

a) génère un  $\epsilon/6m$ -échantillon de  $\Omega(G_{i-1})$

b) si c'est un indépendant de  $G_i$  alors  $X \leftarrow X + 1$

Retourner  $\tilde{r}_i = X/n$ .

Lemma: cet algorithme renvoie une  $(\frac{\epsilon}{6m}, \frac{\delta}{m})$  approximation de  $r_i$ .

Dém. •  $\frac{1}{2} \leq r_i \leq 1$ :  $f: \mathcal{R}(G_{i-1}) \rightarrow \mathcal{R}(G_i)$  ( $G_i = \{u, v\}$ )  
 $\mathcal{I} \mapsto \mathcal{I} \cap \{u, v\}$  si  $(u, v) \notin \mathcal{I}^2$   
 $\mathcal{I} \mapsto \mathcal{I} \cup \{u, v\}$  si  $(u, v) \in \mathcal{I}^2$

$|f^{-1}(\mathcal{I})| \leq 2$  ( $f^{-1}(\mathcal{I}) = \{\mathcal{I}, \mathcal{I} \cup \{u, v\}\}$ )

Donc  $|\mathcal{R}(G_i)| \leq 2 |\mathcal{R}(G_{i-1})|$

• Soit  $X_k = 1$  si le  $k^{\text{e}}$  échantillon est un indep de  $G_i$ , et 0 sinon.

$|P(X_k = 1) - \frac{|\mathcal{R}(G_i)|}{|\mathcal{R}(G_{i-1})|}| \leq \frac{\epsilon}{6m}$  Donc  $|E(X_k) - \frac{|\mathcal{R}(G_i)|}{|\mathcal{R}(G_{i-1})|}| \leq \frac{\epsilon}{6m}$

Mais abs  $|E(\bar{r}_i) - r_i| = |E(\frac{\sum X_k}{n}) - \frac{|\mathcal{R}(G_i)|}{|\mathcal{R}(G_{i-1})|}| = |E(X_k) - \frac{|\mathcal{R}(G_i)|}{|\mathcal{R}(G_{i-1})|}| \leq \frac{\epsilon}{6m}$

•  $E(\bar{r}_i) \geq r_i - \frac{\epsilon}{6m} \geq \frac{1}{2} - \frac{\epsilon}{6m} \geq \frac{1}{2} - \frac{1}{6} = \frac{1}{3}$

Donc on peut choisir  $n \geq \frac{3}{\frac{1}{3}} \frac{\ln(\frac{6m}{\delta})}{(\frac{\epsilon}{12m})^2} = 1296 m^2 \epsilon^{-2} \ln(\frac{6m}{\delta})$  abs

$P(\frac{\bar{r}_i}{E(\bar{r}_i)} - 1 \geq \frac{\epsilon}{12m}) = P(|\bar{r}_i - E(\bar{r}_i)| \geq \frac{\epsilon}{12m} E(\bar{r}_i)) \leq \frac{\delta}{m}$

Donc  $P(1 - \frac{\epsilon}{12m} \leq \frac{\bar{r}_i}{E(\bar{r}_i)} \leq 1 + \frac{\epsilon}{12m}) \geq 1 - \frac{\delta}{m}$

$1 - \frac{\epsilon}{3m} \leq 1 - \frac{\epsilon}{6mr_i} \leq \frac{E(\bar{r}_i)}{r_i} \leq 1 + \frac{\epsilon}{6mr_i} \leq 1 + \frac{\epsilon}{3m}$  ( $r_i \geq \frac{1}{2}$ )

Donc  $P(1 - \frac{\epsilon}{12m} \leq \frac{\bar{r}_i}{r_i} \leq 1 + \frac{\epsilon}{12m}) \geq 1 - \frac{\delta}{m}$

$P(1 - \frac{\epsilon}{2m} \leq \frac{\bar{r}_i}{r_i} \leq 1 + \frac{\epsilon}{2m}) \geq 1 - \frac{\delta}{m}$

Th: Si on dispose d'un FPAUS pour les indep d'un graphe, alors on peut construire un FPRAS pour les indep.

Th (Jerrum, Valiant, Vazirani): #P complet a soit un FPRAS soit est impossible à approximer.

[Pb #P complet si: • Pb  $\in$  #P  
 •  $\forall$  Pb'  $\in$  #P il existe un algo polynomial (deterministe)  $h$  Pb' se réduit à Pb.