

Modèles de calcul, Complexité, Approximation et
Heuristiques

Modèle probabiliste: Algorithmes et Complexité

Jean-Louis Roch

Master-2 Mathématique – Informatique

Grenoble-INP – UJF

Grenoble University, France

Modèle probabiliste: Algorithmes et Complexité

Techniques d'analyse

Plan du cours :

- Retour sur borne inférieure. Principe Min-Max.
- Projection homomorphique
 - sur les polynômes : Schwartz-Zippel (produit de matrices, primalité)
 - sur les entiers : Word-count
- Marche aléatoire. Lien avec chaîne de Markov. 2-SAT.
- Inégalité de Markov. Application à MAX-SAT
- Bornes de Chernoff. Applications : tri, médiane.

Modèle probabiliste: Algorithmes et Complexité

Projection homomorphique

- projection dans un espace plus petit, par hachage
- $\text{prob}(\text{erreur}) = \text{probabilité de collisions}$
- Schémas génériques de projection

- Evaluation d'un polynôme en une abscisse aléatoire (Schwartz-Zippel)
- Calcul modulo un entier [premier] aléatoire

Hachage modulo un nombre premier

Lemme de projection par hachage

Soit $1 \leq N \leq 2^B$ un entier non nul. Soit α un entier. Soit p un nombre premier choisi uniformément parmi les $\pi(\alpha)$ nombre premiers inférieurs à α .

$$\Pr(N \bmod p = 0) \leq \frac{B}{\pi(\alpha)} \leq \frac{B \cdot \log_e \alpha}{\alpha}.$$

Applications

- recherche de chaîne de caractères dans un fichier
- WORD-COUNT : recherche du nombre d'occurrence de k mots de m bits dans un fichier de taille n en temps $O(n)$, indépendant de k .

Lemme de Schwartz-Zippel et exemple

Lemme de Schwartz-Zippel

Soit $P \in K[X_1, \dots, X_n]$ un polynôme non nul à coefficients dans un corps K , à n indéterminées et de degré d .

Soit I un sous-ensemble de K de cardinal $\#I$, soit (u_1, \dots, u_n) tiré uniformément dans I^n . Alors :

$$\Pr(P(u_1, \dots, u_n) = 0) \leq \frac{d}{\#I}.$$

Applications : Preuve probabiliste d'identités algébriques.

- Égalité de deux polynômes.
- Vérification du produit de deux matrices.
- Test de primalité : n est premier ssi $(1 + X)^n = 1 + X^n \pmod{n}$.
- Couplage parfait : ensemble d'arcs tel que chaque sommet est atteint une et une seule fois.

Modèle probabiliste: Algorithmes et Complexité

Lemme de Schwartz-Zippel et exemple

Test de primalité

Propriété : n est premier ssi $(1 + X)^n = 1 + X^n \pmod{n}$.

- Soit $P_n = (1 + X)^n - 1 - X^n$. Alors P est nul ssi n est premier.
- Tirer un polynôme Q de degré petit et calculer $R = P_n \pmod{Q}$. Comment ?
- Vérifier que $R = 0$ en utilisant Schwartz-Zippel.

Couplage parfait

Ensemble d'arcs tel que chaque sommet est atteint une et une seule fois.

- Un couplage parfait existe ssi la matrice antisymétrique de Tutte associé au graphe est inversible ($\det(G) \neq 0$).
si $(i, j) \notin E : T_{i,j} = 0$; sinon si $i < j : T_{i,j} = X_{i,j}$ et $T_{j,i} = -X_{i,j}$.

Modèle probabiliste: Algorithmes et Complexité

Parcours de graphe

- Soit $G = (V, E)$ un graphe non orienté, connexe, à n sommets et m arcs.
- Question : les 2 sommets s et d sont-ils connectés ?
- Un parcours BFS/DFS à partir de s fait cela en temps linéaire $O(n + m)$ et en espace mémoire $O(n)$. Peut-on faire mieux ?

Algorithme probabiliste dans un graphe

Soit $G = (V, E)$ un graphe non orienté, connexe, à n sommets et m arcs.

```
for( r=s; (r ≠ t); r = voisin aléatoire de r );
```

Modèle probabiliste: Algorithmes et Complexité

Marche aléatoire

Temps d'atteinte

$H(i, j)$ = temps moyen pour atteindre j à partir de i pour la première fois.

Exemples

- graphe complet : $H(i, j) = n - 1$ ($i \neq j$)
- chaîne de 0 à $n - 1$: $H(i, j) = j^2 - i^2$ ($i < j$). Donc $H(0, n - 1) = (n - 1)^2$.
- graphe général : $H(i, j) = O(n^3)$

Modèle probabiliste: Algorithmes et Complexité

Matrice de transition

Associé à une chaîne de Markov $M_G = (X_1, X_2, \dots)$ de matrice de transition P , avec $P_{i,j} = \frac{1}{d(i)}$.

- M_G est *irréductible* car on peut aller de tout état à tout autre (G est connexe).
- M_G est *apériodique* ssi chacun de ses états v est non-périodique ;

NB un état v est périodique si

$\exists \Delta > 1 : \Pr[X_{t+s} = v | X_t = v] = 0$ sauf si s multiple de Δ

(i.e. partant de v on ne peut revenir à v qu'après un nombre de pas multiples de Δ).

Remarque : si le graphe n'est pas connecté, ou périodique (par exemple bi-partite), il y a problème de convergence

Chaîne de Markov

Propriétés

Si M_G est finie, irréductible, apériodique, elle admet une unique distribution stationnaire

- $\Pi = (\Pi_1, \dots, \Pi_n)$.
i.e. $\sum_i \Pi_i = 1$ et $\Pi = \Pi \cdot P$.
- Soit $r_{i,j}^k = \Pr[\text{atteindre } j \text{ en } k \text{ pas à partir de } i]$. Le temps moyen pour aller de i à j est $h_{i,j} = \sum_{t \geq 1} t \cdot r_{i,j}^t$.
- Le temps pour aller de i à i est $h_{i,i} = \frac{1}{\Pi_i}$.

Théorème

Soit M_G de distribution stationnaire unique $\Pi = (\Pi_1, \dots, \Pi_n)$:

- $\Pi_i = \frac{\text{deg}(i)}{2m}$.

Preuve : il suffit de vérifier que $\Pi \cdot P = \Pi$ et $\sum_i \Pi_i = 1$.

- Si $(i, j) \in E$: $h_{j,i} < 2m$.

Preuve : on a $h_{i,i} = \frac{2m}{\text{deg}(i)}$ et $h_{i,i} = \sum_{j:(i,j) \in E} \frac{1}{\text{deg}(i)} [1 + h_{j,i}]$. D'où

$$1 + h_{j,i} \leq \sum_{j:(i,j) \in E} [1 + h_{j,i}] = 2m. \text{ Donc } h_{j,i} \leq 2m - 1.$$

- Soit $C_i =$ temps moyen pour atteindre tous les sommets à partir de i (temps de couverture). Alors $C_i < 4nm$.

Preuve : Comme G est connexe, il y a un arbre couvrant de racine i , qui possède n arcs (non orientés). En parcourant cet arbre avec retour à la racine (donc 2 fois chaque arc, soit $2n$ arcs), on parcourt tous les sommets. Donc $C_i \leq$ temps moyen de ce parcours $= 2n \cdot 2m = 4nm$.

Application : en faisant $K = 8nm = O(n^3)$ pas à partir du sommet s , la probabilité de ne pas atteindre la destination t est (inégalité de Markov) $< \frac{4nm}{8nm} < \frac{1}{2}$

Exemple : 2-SAT

Cas particulier : graphe = chaîne

- état à t : $S_t \in \{0, \dots, n\}$. Transitions :

$$\Pr(S_{t+1} = j + 1 | S_t = j) = \Pr(S_{t+1} = j - 1 | S_t = j) = 2^{-1}.$$

- Soit $X_j =$ va qui dénombre le nombre de pas pour aller de j à n :

$$E[X_j] = \frac{1}{2} (1 + E[X_{j+1}]) + \frac{1}{2} (1 + E[X_{j-1}]).$$

- Posons $h_j = E[X_j]$; on a $h_n = 0$, $h_0 = h_1 + 1$ et $h_j = 1 + \frac{1}{2} (h_{j-1} + h_{j+1})$

- Par récurrence, on a : $h_j = h_{j+1} + 2j + 1$

$$h_0 = h_1 + 1; h_{j+1} = 1 + \frac{1}{2} (h_j + h_{j+2}) = 1 + \frac{1}{2} (h_{j+1} + 2j + 1 + h_{j+2})$$

$$\text{d'où } h_{j+1} = h_{j+2} + 2(j + 1) + 1.$$

- D'où $h_0 = h_1 + 1 = \sum_{j=1}^n (2j - 1) = n(n + 1) - n = n^2$

- Inégalité de Markov :

$$\Pr(X_0 > 2n^2) = 1 - \Pr(X_0 \leq 2n^2) \geq 1 - \frac{1}{2} = \frac{1}{2}.$$

Application : PageRank

- A chaque page web, Google associe un nombre caractérisant son importance.
- Le résultat d'une recherche trie les pages par importance décroissante.
- PageRank : calcule l'importance d'une page à partir des liens entre pages :
 - une page A qui pointe vers B : A donne de l'importance à B
 - une page B pointée par beaucoup de pages est importante
 - plus A a de pointeurs, moins chacun a de l'importance
- Equation :

$$R(B) = \sum_{A:A \rightarrow B} R(A)/d(A)$$

avec $d(A) = \# \text{pages pointées par } A$. Attention aux puits !

Les puits accumulent de l'importance sans en donner : l'équation a des solutions avec des poids qu'aux puits, ce qui n'est pas la motivation initiale !

PageRank et marche aléatoire

- Equation corrigée : une fraction du poids de chaque page va vers toutes les pages.

$$R(B) = (1 - \alpha)/N + \alpha \sum_{A:A \rightarrow B} R(A)/d(A)$$

En pratique : $\alpha \simeq 0,85$.

- C'est une marche aléatoire où à chaque page B :
 - avec probabilité α , on suit un lien (aléatoire)
 - avec probabilité $(1 - \alpha)$, on va à une page (aléatoire)
- Comment résoudre avec 100 milliards de pages ?
- La marche aléatoire converge vers la distribution stationnaire !
 - Partir d'une distribution initiale arbitraire.
 - Faire quelques itérations : le résultat est assez proche de la distribution stationnaire (pour Google, 50 à 100 itérations en quelques jours)

Définition

Un événement E se produit

- *surely* (ou *est vrai*) ssi $\mathcal{C}_E = \emptyset$;
- *almost surely* (a.s.) ssi $\Pr(E) = 1$;
- *with overwhelming probability* (w.o.p.) ssi $\forall A > 0, \exists c_A > 0$:

$$\Pr(E) \geq 1 - \frac{c_A}{n^A}$$

– par exemple : $\Pr(E) \geq 1 - e^{-cn}$ avec c constante – ;

- *with high probability* (w.h.p.) ssi $\exists c > 0 : \Pr(E) \geq 1 - n^{-c}$;
- *asymptotically almost surely* (a.a.s.) ssi $\lim_{n \rightarrow \infty} \Pr(E) = 1$.

Formules et encadrement utiles

Formules utiles

Stirling : $n! \simeq \sqrt{2\pi n} \left(\frac{n}{e}\right)^n$.

Coefficients du binôme : $\left(\frac{n}{k}\right)^k \leq C_n^k = \binom{n}{k} \leq \left(\frac{ne}{k}\right)^k$.

Approximation de Poisson : $\left(1 - \frac{a}{n}\right)^n \simeq e^{-a}$.

Inégalités de Markov, Hoeffding, Bienaymé-Tchebychev

- Markov : soit Z une v.a. réelle presque sûrement positive ou nulle :

$$\forall a > 0 : \Pr(Z \leq a) \leq \frac{E[Z]}{a}.$$

- Majoration de l'écart à la moyenne d'une somme de n variables Bernoulli X_k indépendantes avec

$\Pr(X_k = 1) = 1 - \Pr(X_k = 0) = p$. Soit $S_n = \sum_{k=1}^n X_k$, alors :

$\Pr(|S_n - E[S_n]| \geq x\sqrt{n}) \leq 2 \exp(-2x^2)$ (par inégalité de Hoeffding)

$\Pr(|S_n - E[S_n]| \geq x\sqrt{n}) \leq \frac{p(1-p)}{x^2}$ (par Bienaymé-Tchebychev)

Bornes de Chernoff

Variable binomiale et Bornes de Chernoff

Soit X_1, \dots, X_n n variables de Bernouilly, et soit $X = \sum_{i=1}^n X_i$.
Soit p la probabilité de succès et $q = 1 - p$ celle d'échec.

- $\Pr\{X \geq m\} = \sum_{j=m}^n C_n^j p^j q^{n-j}$ (queue de la distribution)
- $\forall 0 < \epsilon < 1 : \begin{cases} \Pr\{X \leq (1 - \epsilon)pn\} & \leq \exp(-\frac{1}{2}\epsilon^2 np) = e^{-\epsilon^2 np/2} \\ \Pr\{X \geq (1 + \epsilon)pn\} & \leq \exp(-\frac{1}{3}\epsilon^2 np) = e^{-\epsilon^2 np/3} \end{cases}$

Autre formulation

- Soit X_1, \dots, X_n des v.a. indépendantes discrètes telles que $\forall i : E[X_i] = 0$ et $|X_i| \leq 1$. Soit $X = \sum_i X_i$ et σ^2 la variance de X . Alors, $\forall \lambda, 0 \leq \lambda \leq 2\sigma : \Pr[|X| \geq \lambda\sigma] \leq 2e^{-\lambda^2/4}$.

Illustration : estimation de la moyenne. Dans une population de N éléments, $p \cdot N$ vérifient une propriété (p est inconnu). On fait n tirages indépendants ; soit X le nombre d'éléments tirés vérifiant la propriété. Alors l'estimation $\frac{X}{n}$ de p vérifie : $\Pr\{\frac{X}{n} = p(1 \pm \epsilon)\} \geq 1 - 2e^{-\epsilon^2 np/2}$.

Modèle probabiliste: Algorithmes et Complexité

MAX-3-SAT

MAX-3-SAT

- Entrée : conjonction de m clauses, chacune avec 3 variables \neq .
- Sortie : le nombre maximal $k \leq m$ de clauses satisfaisables.

Algorithme probabiliste : choisir une affectation aléatoire !

Soit la va $X_i = 1$ si la clause i est satisfaite, 0 sinon.

$\Pr(X_i = 0) = 1/8$, donc

$E[X_i] = 0 \cdot \Pr(X_i = 0) + 1 \cdot \Pr(X_i = 1) = 7/8$.

L'algorithme a un ratio d'approximation à $7/8$ de l'optimal !

Corollaire \exists une affectation qui satisfait au moins $7m/8$ clauses.

Exercice : on tire une affectation tant que moins de $7m/8$ clauses sont satisfaites. Quel est le temps moyen ? Estimer la probabilité d'être proche de cette moyenne (Indication : Chernoff).

Modèle probabiliste: Algorithmes et Complexité

Briser la symétrie aléatoirement

Éléments indépendants dans un cycle

- Entrée : une liste circulaire (cycle) L_0, \dots, L_{n-1} avec $\text{Succ}(L_i) = L_{i+1 \bmod n}$
- Sortie : un ensemble X d'éléments indépendants de grande taille.

Trivial en séquentiel. Mais en parallèle ?

Algorithme parallèle de temps $O(1)$ par tirage aléatoire

- (en parallèle) associer à chaque L_i une couleur $\text{col}(L_i) \in \{0, 1\}$ aléatoire ;
- si $(\text{col}(L_i) = 1)$ et $\text{col}(\text{Succ}(L_i)) = 0$ alors mettre L_i dans X .

Analyse

$\forall 0 < \alpha < \frac{1}{8}$ et soit $\beta = \frac{(1-8\alpha)^2}{16}$. On a : $\Pr\{|X| \leq \alpha n\} \leq e^{-\beta n}$.
[Chernoff avec $|X| > n/2$ tirages de Bernouilly de probabilité de succès $1/4$]

Modèle probabiliste: Algorithmes et Complexité

Preuve à faire au tableau :

- Un élément x est sélectionné ssi il est colorié avec 1 et son successeur avec 0 : cet évènement est de probabilité $1/4$.
- Pour se ramener à des Bernouilly indépendantes, on se limite à une borne inf sur les éléments x_{2i} d'indice pair.
Soit X_{2i} la v.a. de Bernouilly de probabilité de succès $1/4$ et qui vaut 1 ssi x_{2i} est sélectionné. Il y a $n/2$ va X_{2i} indépendantes.
Soit $Y = \sum_{i=0}^{n/2} X_{2i}$ et soit C la va qui dénombre le nombre d'éléments sélectionnés : on a $C \geq Y$.
- Chernoff : $\Pr(Y < (1 - \epsilon)n/8) < \exp(-\epsilon^2 n/16)$.
On choisit ϵ en posant $\alpha = (1 - \epsilon)/8$ soit $\epsilon = 1 - 8\alpha$: pour $\alpha \in]0, 1/8[$, on a bien $\epsilon > 0$ et aussi $\beta = (1 - 8\alpha)^2/16 > 0$; donc $\forall \alpha \in]0, 1/8[$: $\Pr(C < \alpha n) \leq \Pr(Y < \alpha n) < \exp(-\beta n)$.
- Par exemple, avec $\alpha = 1/16$:
 $\Pr(C < n/16) < e^{-64n} < (2 \cdot 10^{-28})^n$.
Donc $C > n/16$ w.h.p. (et même très grande probabilité !)

Modèle probabiliste: Algorithmes et Complexité

Médiane

- entrée : n éléments a_0, \dots, a_{n-1} d'un ensemble ordonné.
- sortie : l'élément de rang k (par exemple, $k = n/2$)

Algorithme RandomMedian(i, j, k)

- 1 si $(j - i == 1)$ retourner a_j ;
- 2 choisir p au hasard dans $i, \dots, j - 1$
- 3 $r := \text{segmenter}(i, j, p)$; // r est la position de a_p
- 4 si $r = k - 1$ retourner a_p ;
- 5 si $rs \gg k$ retourner RandomMedian(i, r, k);
- 6 sinon retourner $(r + 1, j, k - r - 1)$;

Analyse : Soit X_j le nombre d'éléments à l'étape j .

$\Pr(X_{j+1} \leq 3/4 X_j) = 1/2$: donc le nombre moyen d'appels pour diviser par $4/3$ est 2. D'où $E[X] = \sum_j E[X_j] \leq \sum_j 2(3/4)^j n = 8n$.

Quicksort probabiliste - Analyse

Borner la probabilité $\text{Prob}_{\text{échec}}^{(e)}(t)$ qu'un élément arbitraire e du tableau à trier soit mal placé après t partitions sur cet élément.

- Soit n_j la taille du sous-tableau contenant e après j étapes de partition.
Alors : $\Pr\left(n_{j+1} \leq \frac{3n_j}{4}\right) \geq \frac{1}{2}$.
Une telle partition est dite réussie.
- Après $\log_{4/3} n$ partitions réussies, e est correctement placé.
- Soit la v.a. $X_t = \# \text{partitions réussies}$: $\Pr_{\text{échec}}^{(e)}(t) = \Pr(X_t \leq \log_{4/3} n)$.
- [Chernoff] choisir ϵ tel que $(1 - \epsilon)pt = \log_{4/3} n$: $\epsilon = 1 - \frac{2}{t} \log_{4/3} n \in]0, 1[$ pour $t > 2 \log_{4/3} n$.
- Finalement, en prenant $t = 5 \log_{4/3} n$, on a :

$$\text{Prob}_{\text{échec}}^{(e)} = n \text{Prob}_{\text{échec}}^{(e)}(5 \log_{4/3} n) < n^{1 - \frac{9}{5} \times 0.86} < n^{-0.54} < \frac{1}{\sqrt{n}}$$

- Exercice : Reprendre le calcul avec $\Pr\left(n_{j+1} \leq \frac{7n_j}{8}\right) \geq \frac{3}{4}$.

Trouver x_n l'élément médian de l'ensemble ordonné $\{x_1, \dots, x_{2n-1}\}$.

Algorithme

- Choisir Y de taille $2n^{2/3}$;
- Trier Y et prendre $a = Y_{n^{2/3} - n^{1/3} \log n}$ et $b = Y_{n^{2/3} + n^{1/3} \log n}$
- Calculer $Z := X \cap [a, b]$, en comptant $n_a = \# \text{éléments} < a$.
Avec une grande probabilité, $x_n \in Z$ et $Z < 2n^{2/3} \log n$ [Chernoff].
- Trier Z et retourner $x_n = z_{n-n_a}$.

Coût moyen : $\frac{3}{2}n + o(n)$ comparaisons !