

Techniques algébriques

Objectif: Utiliser des résultats (simples) d'algèbre et théorie des nombres pour concevoir et analyser des algorithmes probabilistes.

Structure commune: Calcul d'empreintes (fingerprinting) pour passer d'objets de grande taille à des objets "petits".

1. Algorithme de Freivalds (1977)

Entrée Trois matrices A, B, C de taille $n \times n$ à coefficients dans un corps ($\mathbb{Q}, \mathbb{F}_p, \dots$)

Sortie Vrai/Faux: est-ce que $A \times B = C$

1. Choisir aléatoirement un vecteur r de bits, de taille n
2. Calculer $A \times (B \times r)$ et $C \times r$
3. Répondre "Vrai" si les résultats sont égaux, "Faux" sinon

Exemple $A = \begin{bmatrix} 2 & 3 \\ 3 & 4 \end{bmatrix}$ $B = \begin{bmatrix} 1 & 0 \\ 1 & 2 \end{bmatrix}$ $C = \begin{bmatrix} 6 & 5 \\ 7 & 7 \end{bmatrix}$

$\cdot r = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ $A \times (B \times r) = \begin{bmatrix} 2 & 3 \\ 3 & 4 \end{bmatrix} \times \begin{bmatrix} 1 \\ 3 \end{bmatrix} = \begin{bmatrix} 11 \\ 15 \end{bmatrix} = C \times r$

$\cdot r = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$ $A \times (B \times r) = \begin{bmatrix} 2 & 3 \\ 3 & 4 \end{bmatrix} \times \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 5 \\ 7 \end{bmatrix} \neq \begin{bmatrix} 6 \\ 7 \end{bmatrix} = C \times r$

Complexité 3 produits matrice x vecteur : $\Theta(n^2)$.

↳ le produit de matrices se calcule en $\Theta(n^3)$ par l'algorithme naïf, $\Theta(n^{2.8...})$ par l'algorithme de Strassen et $\Theta(n^{2.3728639...})$ pour le meilleur algo connu (Le Gall 2014).

⇒ Freivalds permet de vérifier rapidement et simplement.

Correction Si $A \times B = C$, alors $A \times (B \times r) = (A \times B) \times r = C \times r$.

Donc l'algorithme est correct si $AB = C$.

Lemme Si $A \times B \neq C$, l'algorithme répond "Vrai" avec proba $\leq \frac{1}{2}$.

Preuve Soit $D = AB - C \neq 0$. On écrit $D = (D_{ij})_{i,j}$

et on fixe un vecteur $r = \begin{pmatrix} r_1 \\ \vdots \\ r_n \end{pmatrix}$.

Alors $D \cdot r = \begin{pmatrix} d_1 \\ \vdots \\ d_n \end{pmatrix}$ où $d_i = \sum_{k=1}^n D_{ik} r_k$.

Soit j tq $D_{ij} \neq 0$. Alors $d_i = D_{ij} r_j + y$.

$$\mathbb{P}[d_i = 0] = \underbrace{\mathbb{P}[d_i = 0 \mid y = 0]}_{\mathbb{P}[r_j = 0] = \frac{1}{2}} \mathbb{P}[y = 0] + \underbrace{\mathbb{P}[d_i = 0 \mid y \neq 0]}_{\mathbb{P}[r_j = 1] = \frac{1}{2}} \mathbb{P}[y \neq 0]$$

$$= \frac{1}{2} \mathbb{P}[y = 0] + \frac{1}{2} \mathbb{P}[y \neq 0] = \frac{1}{2}.$$

$$\Rightarrow \mathbb{P}[d = 0] = \mathbb{P}\left[\bigwedge_{i=1}^n d_i = 0\right] \leq \mathbb{P}[d_i = 0] \leq \frac{1}{2} \cdot \square$$

Conclusion L'algo de Freivalds permet de tester une égalité entre 2 matrices en $\mathcal{O}(n^2)$ opérations sans calculer explicitement les matrices.

Il ne peut se tromper que si l'égalité n'a pas lieu, avec proba $\leq \frac{1}{2}$. En répétant le fais, proba d'erreur $\leq \frac{1}{2^k}$.

Remarque $A \times (B \times r)$ et $C \times r$ sont les empreintes de $A \times B$ etc.

Fausse bonne idée Tirer aléatoirement r dans un ensemble plus grand: par exemple, $r \in S^n$ où S est un ensemble quelconque. Alors $P[\text{erreur}] \leq \frac{1}{|S|}$.

↳ Avec $n \cdot \log |S|$ bits, on atteint $\frac{1}{|S|}$. Si on prend $n \cdot \log |S|$ bits dans l'algo. de Freivalds, on obtient une borne

$$\frac{1}{2} \log |S| = \frac{1}{|S|} \rightarrow \text{Pareil!}$$

Oui mais: multiplications plus coûteuses!

2. Égalité d'entiers — Application à la recherche de motifs

Exemple Vous avez (légalement !) téléchargé votre livre préféré d'algèbre probabilistes. Vous voulez vérifier son intégrité. Comment faire ?

Modélisation $A = a_0 \dots a_N$ et $B = b_0 \dots b_N$ sont 2 chaînes de caractères sur un alphabet Σ de taille β .
On veut tester l'égalité $A \stackrel{?}{=} B$ avec le moins d'échanges possibles.

Idée 1. Voir A et B comme des entiers en base β :
on numérote les éléments de Σ de 0 à $\beta-1$, et on définit $n_A = \sum_{i=0}^N a_i \beta^i$ et $n_B = \sum_{i=0}^N b_i \beta^i$.

2. On choisit un nombre premier p d'écartement et on calcule $n_A \bmod p$ et $n_B \bmod p$.

3. On prétend que $A = B$ si $n_A = n_B \bmod p$.

Questions Combien de bits échangés ? Quelle quantité sur le résultat ?

Théorème . Si $A=B$, l'algo fonctionne à tous les coups. 5
 . Si $A \neq B$ et que p est choisi $\leq \epsilon N \log(\epsilon N)$,
 la proba. de mauvaise réponse $\leq 1/\epsilon$

. le nombre de bits échangés est $\Theta(\log N)$.
 $+ \log t$

Preuve . $n_A \bmod p = n_B \bmod p$ ssi p divise $n_A - n_B$

. le nb de diviseurs premiers de $n_A - n_B$ est $\leq N$

$\hookrightarrow n_A, n_B \leq 2^{N+1}$, donc $n_A - n_B < 2^{N+1}$. Or chaque
 diviseur premier est ≥ 2 . Donc $2^{\# \text{diviseurs}} \leq n_A - n_B < 2^{N+1}$.

Thm des nombres premiers : $\pi(n) \sim n / \log n$

$$\begin{aligned} \hookrightarrow P[p \text{ divise } n_A - n_B] &\leq \frac{\# \text{diviseurs de } n_A - n_B}{\# \text{premiers } \leq \epsilon N \log(\epsilon N)} \\ &\leq \frac{N}{\pi(\epsilon N \log \epsilon N)} \leq \Theta(1/\epsilon). \quad \square \end{aligned}$$

\Rightarrow Avec $t=N$: on peut tester l'égalité avec $\Theta(\log N)$
 bits échangés, avec proba d'erreur $\leq \Theta(1/N)$.

(+ répétitions $\leadsto \Theta(1/N^k)$)

Application Recherche de motif dans un texte.

Entrée Texte $X = x_1 \dots x_n$, motif $Y = y_1 \dots y_m$

Sortie(s) Y apparaît-il dans X ? Combien de fois? Où?...

Formalisation On note, pour $0 \leq j \leq n-m+1$,

$$X(j) = x_j \dots x_{j+m-1}.$$

↳ Trouver (compter) j tq $X(j) = Y$.

Algos déterministes Naïf en $\Theta(m \times n)$: on teste tous les j
Optimal en $\Theta(n+m)$ [KMP]

Idée $Y \rightsquigarrow n_y$, $X(j) \rightsquigarrow n_j$, + test $n_y \stackrel{?}{=} n_j [p]$

Algo 1. Tirer p aléatoirement $\leq \bar{c}$ (à prévoir)

2. $n_y \leftarrow \sum_{i=1}^m y_i \beta^{i-1} \pmod p$

3. $n_x \leftarrow \sum_{i=1}^m x_i \beta^{i-1} \pmod p$

4. Pour $j=1$ à $n-m+1$:

5. | Si $n_y = n_x$: Renvoyer j

6. | $n_x \leftarrow \beta \times (n_x - \beta^{m-1} x_j) + x_{j+m} \pmod p$

7. Renvoyer "Pas trouvé"

7
Complexité 2,3. $\Theta(m)$ si opérations mod p coûtent 1.
(OK pour p petit)

6. Temps constant: si $\beta=2$ par exemple, ce ne sont que des décalages et une arithmétique mod p .

↳ $\Theta(n+m)$ si arithmétique en $\Theta(1)$.

Correction Probabilité de faux positif:

$$P[n_x = n_y \mid X(j) \neq Y] \leq \frac{m}{\pi(\tau)} = \Theta\left(\frac{m \log \tau}{\tau}\right)$$

↳ Pour tester l'existence d'un motif, faux positif avec proba $\leq \Theta\left(N \frac{m \log \tau}{\tau}\right)$.

\Rightarrow Avec $\tau = N^2 m \log(N^2 m) \rightarrow \leq \Theta(1/N)$.

Variante On a un algo Monte Carlo: très rapide, souvent just.

Si à chaque égalité $n_x = n_y$ [p], on teste (bêtement) l'égalité des chaînes: l'espérance du nombre de tests est petit si $X(j) \neq Y$.

Solutions: 1. Au premier test, si c'est un faux positif, on branche l'algo naïf. Espérance $\Theta\left((n+m)\left(1-\frac{1}{n}\right) + \frac{1}{n}nm\right) = \Theta(n+m)$.

2. On change p : après t chgts $\Theta(1/n^t)$ risques.

3. Egalités polynomiales - Complexes racines

- Polynôme $12x^4 + 5x^3 + 7x^2 - 3x - 1$

$\hookrightarrow p(x) = \sum_{i=0}^d a_i x^i$: polynôme univarié de degré d .

- Vérification du produit de polynômes:

$$x \quad p(x) = \sum_{i=0}^d a_i x^i \quad q(x) = \sum_{i=0}^d b_i x^i$$

$$\hookrightarrow p(x) \times q(x) = r(x) = \sum_{i=0}^{2d} c_i x^i$$

où $c_i = \sum_{j+k=i} a_j b_k$. \rightarrow Complexité (op. arithmétiques) $\rightarrow \begin{matrix} \nearrow \Theta(d^2) \\ \searrow \Theta(d \log d) \end{matrix}$

x Algo de vérification:

1. Choisir a aléatoirement dans un ensemble S

2. Evaluer $p(a)$, $q(a)$ et $r(a)$.

3. Accepter si $p(a)q(a) = r(a)$.

\rightarrow Complexité: d opérations arithmétiques.

$$\rightarrow \mathbb{P}[\text{échec}] = \mathbb{P}[(p \times q - r)(a) = 0 \mid p \times q \neq r]$$

$$= \mathbb{P}[a \text{ racine de } p \times q - r \mid p \times q \neq r] = \frac{\# \text{ racines}}{|S|}$$

\hookrightarrow Si $|S| > 2d+1$, $\mathbb{P}[\text{échec}] < \frac{1}{2}$.

9
- Problème : les évalués de P, Q, r peuvent être grands!

→ Solution : Faire les calculs modulo p_1 ou p_2 et un premier choisi aléatoirement :

$$\text{Comme } (a \times b) \bmod p = [(a \bmod p) \times (b \bmod p)] \bmod p \\ \text{et } (a + b) \bmod p = [(a \bmod p) + (b \bmod p)] \bmod p$$

$P(a) \bmod p_1$ peut se calculer en faisant des calculs modulo p_1 .

$$\hookrightarrow \mathbb{P} [P(a) \bmod p_1 = 0 \mid P(a) \neq 0] \leq \frac{\# \text{diviseurs premiers de } p_1}{\text{taille de l'ensemble où on tire } p_1}$$

- Généralisation Considérons $\Pi = \begin{pmatrix} 1 & x_1 & \dots & x_1^{n-1} \\ 1 & x_2 & \dots & x_2^{n-1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & \dots & x_n^{n-1} \end{pmatrix}$

la matrice de van der Monde. Je prétends

que $\det(\Pi) = \prod_{i \neq j} (x_i - x_j)$. Comment vérifier?

⇒ On veut un analogue du test de polynômes mais pour les polynômes à plusieurs variables.

Def . $p(x_1, \dots, x_n) = \sum_{j=0}^k p_j x_1^{d_{1j}} \dots x_n^{d_{nj}}$

↳ exemple : $p(x) = 3x^2yz + 2xy^2 - z^3 + 2y + 1$

Addition $\sum_{j=0}^k (p_j + q_j) x^{d_j}$

Multiplication $\sum_{j=0}^k \sum_{l=0}^k p_j q_l x_1^{d_{1j} + d_{1l}} \dots x_n^{d_{nj} + d_{nl}}$

↳ exemple : $p(x) \cdot (3xy + z) = 9x^3y^2z + 6x^2y^3 + \dots + 2yz + z$

Thm Soit $P \in \mathbb{K}[x_1, \dots, x_n]$ de degré d et $S \subseteq \mathbb{K}$.

Alors $\mathbb{P}[\underbrace{P(r_1, \dots, r_n) = 0}_{r_1, \dots, r_n \in S} \mid P \neq 0] \leq \frac{d}{|S|}$

Preuve par récurrence sur n

$n=1$: $P(x)$ de degré $\leq d$ a au plus d racines.

$\mathbb{P}[P(r) = 0 \mid P \neq 0] = \mathbb{P}[r \in Z(P)] = \frac{|Z(P)|}{|S|} \leq \frac{d}{|S|}$

$n \geq 2$: $P = \sum_{i=0}^k x_1^i P_i(x_2, \dots, x_n)$ avec $P_k \neq 0$.

$\mathbb{P}[P_k(r_2, \dots, r_n) = 0 \mid P_k \neq 0] \leq \frac{d-k}{|S|}$ [par récurrence].

On définit $q(x_1) = P(x_1, r_2, \dots, r_n)$. $\mathbb{P}[q(r_1) = 0] \leq k/|S|$

$\Rightarrow \mathbb{P}[P(r_1, \dots, r_n) = 0 \mid P \neq 0] \leq \mathbb{P}[P_k(r_2, \dots, r_n) = 0 \mid P_k \neq 0] + \mathbb{P}[P(x_1, r_2, \dots, r_n) = 0 \mid P_k \neq 0]$
 $\leq \frac{d-k}{|S|} + k/|S| = d/|S|$ □

- Application : test d'égalité entre polys $PQ \stackrel{?}{=} R$

1. Choisir $r_1, \dots, r_n \in S$.
2. Évaluer $P(r)$, $Q(r)$ et $R(r)$.
3. Accepter si $P(r)Q(r) = R(r)$.

↳ Correction $P[\text{échec}] \leq \frac{\deg(R)}{|S|}$.

↳ Complexité x Coût de l'évaluation \rightarrow ça dépend
x Si besoin, calcul modulo un premier.

- Vraie application : Couplage parfait dans un graphe biparti

Entrée $G = (U, V, E)$ avec $E \subseteq U \times V$ et $|U| = |V|$.

Sont $C \subseteq E$ tq $|C| = |U| = |V|$ et

$$\begin{cases} \forall u \in U \exists ! c \in C \text{ "u} \in c\text{"} \\ \forall v \in V \exists ! c \in C \text{ "v} \in c\text{"} \end{cases}$$

Def Matrice d'adjacence symbolique de G :

$$A = (A_{ij})_{ij} \text{ avec } A_{ij} = \begin{cases} x_{ij} \text{ si } (u_i, v_j) \in E \\ 0 \text{ sinon.} \end{cases}$$

1. — .1
2. ~~X~~ .2
3. ~~X~~ .3

$$\rightarrow \begin{pmatrix} x_{11} & 0 & x_{13} \\ 0 & x_{22} & 0 \\ x_{31} & x_{32} & 0 \end{pmatrix}$$

Then G a un couplage parfait

$\Leftrightarrow \det(A)$ est un polynôme non nul.

Rappel $\det \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} = -2$. $\det A = \sum_{\sigma \in S_n} \text{sgn}(\sigma) \prod_{i=1}^n A_{i, \sigma(i)}$

Preuve Si $\sigma_1 \neq \sigma_2$, $\prod_{i=1}^n A_{i, \sigma_1(i)} \neq \prod_{i=1}^n A_{i, \sigma_2(i)}$
(sauf si nuls)

Jonc: $\det(A) \neq 0 \Leftrightarrow \exists \sigma \prod_{i=1}^n A_{i, \sigma(i)} \neq 0$
 $\Leftrightarrow \exists \sigma \forall i: A_{i, \sigma(i)} \neq 0$
 $\Leftrightarrow \exists \sigma \forall i: A_{i, \sigma(i)} = x_{i, \sigma(i)}$
 $\Leftrightarrow \exists \sigma \forall i: (u_i, v_{\sigma(i)}) \in E$
 $\Leftrightarrow G$ admet un couplage parfait. \square

- Algo 1 Choisir des poids aléatoires $r_{ij} \in S$ sur chaque arête
1. Evaluer $\det(A(r_{11}, \dots, r_{nn})) =: \Delta$
 2. Accepter si $\Delta \neq 0$.

Complexité Coût d'un déterminant $\sim \mathcal{O}(n^3)$ ou $\mathcal{O}(n^\omega)$.
 \hookrightarrow pas top, mais parallélisable.

Correction $\mathbb{P}[\text{échec}] \leq \frac{\deg(\det(A))}{|S|} = \frac{n}{|S|}$.

4. Conclusion : comparaisons

13

- Freivalds = cas particulier de Schwartz-Zippel:

Soit z_1, \dots, z_n des variables, et $P_{AB} = A \cdot B = \begin{pmatrix} z_1 \\ \vdots \\ z_n \end{pmatrix}$, ~~$P_A = A$~~ ~~$P_B = B$~~
et $P_C = C = \begin{pmatrix} z_1 \\ \vdots \\ z_n \end{pmatrix}$. Alors $A \cdot B = C \Leftrightarrow P_{AB} = P_C$.

- Vision commune de 2. et 3.

Etant donné $A = a_0 \dots a_n$, construisons $P_A = \sum_{i=0}^n a_i X^i$.

Alors 2. $\Leftrightarrow P_A(\beta) \bmod q = 0?$
base \nearrow β aléatoire

3. $\Leftrightarrow P_A(\alpha) \bmod p = 0?$
aléatoire \nearrow α > base

- Troisième possibilité :

Prendre P aléatoirement et évaluer $P(A)$ et $P(B)$
(modulo un nb premier) \rightarrow avec good proba, $P(A) \neq P(B)$ si $A \neq B$.
 \Rightarrow Idée des fonctions de hachage (spoiler).