

3.1 Test d'associativité

Soit S un ensemble fini à n éléments, muni d'une loi de composition interne \circ .

But : On veut déterminer si \circ est associative. On mesure la complexité en comptant le nombre d'opérations effectuées (au sens de \circ).

Théorème 3.1. *Il existe un algorithme probabiliste de type one-sided error répondant à ce problème en $\mathcal{O}(n^2)$ opérations¹.*

Preuve: Soit p un nombre premier ; notons $\mathcal{S} = \mathbb{Z}_p[S]$ le \mathbb{F}_p -espace vectoriel des vecteurs $x = (x_i)_{i \in S}$ à coordonnées dans \mathbb{F}_p .

On note, pour tout $i \in S$, e_i le i -ième vecteur de la base canonique de \mathcal{S} , et on munit \mathcal{S} d'une loi de composition interne $\tilde{\circ}$ définie sur la base canonique par

$$\forall (i, j) \in S^2, e_i \tilde{\circ} e_j = e_{i \circ j}$$

puis étendue par linéarité à tout l'espace : pour tous les vecteurs $(x = \sum_{i \in S} x_i e_i, y = \sum_{j \in S} y_j e_j) \in \mathcal{S}^2$,

$$x \tilde{\circ} y = \sum_{(i,j) \in S^2} x_i y_j e_{i \circ j}$$

Remarquons qu'on peut ré-écrire cette égalité sous la forme

$$x \tilde{\circ} y = \sum_{k \in S} \left(\sum_{(i,j) \in S^2 / i \circ j = k} x_i y_j \right) e_k \quad (3.1)$$

On va montrer, en utilisant le lemme 3.2 ci-dessous que l'algorithme suivant répond aux spécifications du théorème :

1. C'est clairement mieux qu'un algorithme exhaustif naïf en n^3 opérations. On peut même se convaincre qu'on ne peut pas faire mieux ; on est bien obligés de construire la "table" de \circ : en effet, soient i_0 et j_0 deux éléments arbitraires de S , et soit $k_0 \neq i_0$, considérer par exemple la loi \circ définie par

$$\begin{cases} i_0 \circ j_0 = k_0 \\ \forall (i, j) \neq (i_0, j_0), i \circ j = i_0 \end{cases}$$

ALGORITHME

1. Tirer au hasard trois vecteurs $(x, y, z) \in \mathcal{S}^3$
2. Calculer $[(x \tilde{\circ} y) \tilde{\circ} z - x \tilde{\circ} (y \tilde{\circ} z)]$
3. Renvoyer VRAI si ce vecteur est nul, FAUX sinon.

* Tout d'abord, sa complexité est bien en $\mathcal{O}(n^2)$ opérations sur S , d'après la définition de $\tilde{\circ}$.

* Ensuite, d'après le lemme 3.2, si \circ est associative, il renvoie toujours VRAI

* Supposons enfin que \circ n'est pas associative, et calculons la probabilité d'erreur de notre algorithme.

Soient $(x = \sum_{i \in S} x_i e_i, y = \sum_{j \in S} y_j e_j, z = \sum_{k \in S} z_k e_k) \in \mathcal{S}^3$. Calculons, pour $l \in S$ fixé, la l -ième coordonnée du vecteur $(x \tilde{\circ} y) \tilde{\circ} z - x \tilde{\circ} (y \tilde{\circ} z)$, qu'on notera $P_l(x, y, z)$.

En utilisant (3.1), on obtient

$$P_l(x, y, z) = \left(\sum_{(i,j,k) \in S^3 / i \circ (j \circ k) = l} x_i y_j z_k \right) - \left(\sum_{(i,j,k) \in S^3 / (i \circ j) \circ k = l} x_i y_j z_k \right)$$

qui est donc un polynôme de degré 3 sur \mathbb{F}_p (en $(x_i, y_j, z_k)_{(i,j,k) \in S^3}$). D'après le théorème de Schwartz-Zippel,

$$[P_l \neq 0] \implies \left[\mathbb{P}_{(z,y,z) \in S^3} (P_l(x, y, z) \neq 0) \geq 1 - \frac{\deg(P_l)}{|\mathbb{F}_p|} \geq 1 - \frac{3}{p} \right]$$

Or, comme \circ n'est pas associative, d'après le lemme 3.2, il existe l dans S tel que $P_l \neq 0$. Ainsi, la probabilité d'erreur pour notre algorithme est inférieure à $\frac{3}{p}$.

□

Démontrons maintenant le lemme utilisé dans la preuve du théorème.

Lemme 3.2. \circ est associative dans S si et seulement si $\tilde{\circ}$ est associative dans \mathcal{S}

Preuve:

\implies Calculons pour $(x = \sum_{i \in S} x_i e_i, y = \sum_{j \in S} y_j e_j, z = \sum_{k \in S} z_k e_k) \in \mathcal{S}^3$,

$$\begin{aligned} (x \tilde{\circ} y) \tilde{\circ} z &= \left(\sum_{(i,j) \in S^2} x_i y_j e_{i \circ j} \right) \tilde{\circ} \left(\sum_{k \in S} z_k e_k \right) \\ &= \sum_{(i,j,k) \in S^3} x_i y_j z_k \underbrace{e_{i \circ j} \tilde{\circ} e_k}_{= e_{(i \circ j) \circ k}} \end{aligned}$$

On obtient de même

$$x \tilde{\circ} (y \tilde{\circ} z) = \sum_{(i,j,k) \in S^3} x_i y_j z_k e_{i \circ (j \circ k)}$$

Or, comme \circ est associative dans S , on a

$$\forall (i, j, k) \in S^3, (i \circ j) \circ k = i \circ (j \circ k)$$

d'où l'égalité voulue

$$(x \tilde{\circ} y) \tilde{\circ} z = x \tilde{\circ} (y \tilde{\circ} z)$$

\Leftarrow Il suffit de remarquer que $S \subset \mathcal{S}$ par

$$i \rightsquigarrow e_i$$

□

3.2 Retour sur k -SAT

On rappelle brièvement le problème k -SAT introduit au cours 2 : on considère une formule $\varphi = \bigwedge_i C_i$ où les C_i sont des k -clauses, ie des unions de k littéraux choisis parmi n variables logiques $(x_i)_{1 \leq i \leq n}$ et leurs négations. Le but est de trouver une affectation a de ces variables logiques telles que $\varphi(a) = 1$.

3.2.1 Walk-SAT itéré pour 3-SAT

Considérons l'algorithme suivant :

ALGORITHME

1. Tirer au hasard (uniformément) une affectation $a \in \{0; 1\}^n$
2. Répéter au plus $3n$ fois la boucle suivante :
 - Si $\varphi(a) = 1$, renvoyer a , et arrêter l'algorithme
 - Sinon, choisir une clause C telle que $C(a) = 0$, choisir un indice i tel que x_i apparaît dans C , et changer la valeur correspondante dans a (ie $a_i \leftarrow 1 - a_i$)
3. Retour en 1.

⚡ Pour éviter les confusions, on parlera dans la suite d'*itérations* pour désigner le retour en 1 et le tirage aléatoire d'une nouvelle affectation initiale, par opposition aux *tours de boucle* internes à l'étape 2, avec une affectation initiale a donnée.

Théorème 3.3. *Il existe une constante K telle que si φ est satisfiable, pour toute affectation initiale a*

$$\underbrace{\mathbb{P}(\text{l'algorithme termine en moins de } 3n \text{ tours de boucle})}_{:=p} \geq \underbrace{\frac{K}{\sqrt{n}} \left(\frac{3}{4}\right)^n}_{:=q}$$

Preuve: Soit a une affectation initiale donnée; posons $s \in \{0; 1\}^n$ une solution de φ , et $X =$ le nombre de bits différents entre a et s . Notons par ailleurs

$$\forall j \in \llbracket 0; n \rrbracket, p_j = \mathbb{P}(\text{l'algorithme termine en moins de } 3n \text{ tours de boucle} \mid X = j)$$

On a par la formule de Bayes

$$p = \sum_{j=0}^n p_j \underbrace{\mathbb{P}(X = j)}_{= \frac{\binom{n}{j}}{2^n}}$$

Or, on a l'inégalité

$$p_j \geq \mathbb{P}(\text{l'algorithme termine en exactement } 3j \text{ tours de boucle} \mid X = j)$$

ce qui permet, en se ramenant à une marche aléatoire sur \mathbb{Z} entier² d'écrire l'inégalité

$$\begin{aligned} p_j &\geq \mathbb{P}(\text{l'algorithme effectue } 2j \text{ pas à gauche et } j \text{ pas à droite}) \\ &\geq \binom{3j}{j} \left(\frac{2}{3}\right)^j \left(\frac{1}{3}\right)^{2j} \end{aligned}$$

la dernière inégalité venant du fait qu'on sélectionne une variable parmi les 3 de la clause non vérifiée, et qu'on a donc au moins une chance sur 3 que cette variable soit fausse (et même plus, puisque 2, voire les 3 variables peuvent être fausses).

Or, d'après la formule de Stirling,

$$\exists K / \binom{3j}{j} \sim \frac{K}{\sqrt{j}} \left(\frac{27}{4}\right)^j$$

d'où il vient pour n assez grand

$$\begin{aligned} p &\geq \sum_{j=0}^n \frac{\binom{n}{j}}{2^n} \binom{3j}{j} \frac{2^j}{3^{3j}} \\ &\geq \sum_{j=0}^n \frac{K}{2^n} \binom{n}{j} \frac{1}{\sqrt{j} 2^j} \\ &\geq \frac{K}{\sqrt{n}} \left(\frac{3}{4}\right)^n \end{aligned}$$

□

Corollaire 3.4. Dans l'algorithme précédent, l'espérance du nombre d'itérations est plus petite que

$$\frac{1}{q} = \frac{\sqrt{N}}{k} \left(\frac{4}{3}\right)^n$$

On re-tombe sur des performances exponentielles, ce qui est plutôt normal, 3-SAT étant NP-complet...

2. Cas clairement moins favorable que la marche aléatoire absorbante en 0 et repoussante en n que l'on considérait jusqu'à présent.

3.2.2 Généralisation à k -SAT

Théorème 3.5. Avec le même algorithme, si φ est satisfiable, le nombre moyen d'itérations est majoré par $(\frac{1}{2}(1 + \frac{1}{k}))^{-n}$.

Preuve: Reprenons les mêmes notations et les mêmes idées : on se ramène à une marche aléatoire sur \mathbb{Z} tout entier, et on majore cette fois p_j par

$$\begin{aligned} p_j &\geq \sum_{i=0}^j \mathbb{P}(\text{l'algorithme effectue } j+i \text{ pas à gauche et } i \text{ pas à droite}) \\ &\geq \sum_{i=0}^j \binom{2i+j}{i} \left(\frac{k-1}{k}\right)^i \left(\frac{1}{k}\right)^{i+j} \\ &\geq \left(1 + \frac{1}{k}\right)^j \end{aligned}$$

d'où le résultat en sommant par la formule du binôme. □

3.2.3 Exercice : application à la 3-COLORIABILITÉ

Soit $G = (X, E)$ un graphe non-orienté 3-coloriable, c'est-à-dire qu'il existe une application $C : X \rightarrow \llbracket 0; 2 \rrbracket$ telle que

$$\forall (x, y) \in X^2, (x, y) \in E \Rightarrow c(x) \neq c(y)$$

On cherche un algorithme qui colorie G avec seulement 2 couleurs, de telle sorte qu'aucun triangle ne soit mono-chromatique.

Soit une application $a : X \rightarrow \llbracket 0; 1 \rrbracket$; considérons l'ensemble T des triangles de G , c'est-à-dire les sommets $(i, j, k) \in X^3$ tels que

$$\begin{aligned} (i, j) &\in E \\ (j, k) &\in E \\ (i, k) &\in E \end{aligned}$$

et pour chaque triangle posons la clause logique $C_{i,j,k} = (a(i) \vee a(j) \vee a(k)) \wedge (\overline{a(i)} \vee \overline{a(j)} \vee \overline{a(k)})$.

La formule logique

$$\varphi = \bigwedge_{(i,j,k) \in T} C_{i,j,k}$$

est une formule 3-SAT satisfiable, puisqu'il suffit par exemple de poser

$$a : \begin{cases} X & \longrightarrow & \llbracket 0; 1 \rrbracket \\ x & \longmapsto & \begin{cases} 0 & \text{si } C(x) = 0 \\ 1 & \text{sinon} \end{cases} \end{cases}$$

où C est le 3-coloriage existant par hypothèse ; on est donc ramenés à la résolution de 3-SAT, qu'on peut par exemple traiter avec WALK-SAT.

3.3 S-T CONNECTIVITÉ

3.3.1 Cas général

Soient $G = (X, E)$ un graphe non-orienté et $(s, t) \in X^2$ deux sommets fixés de G . On cherche à déterminer s'il existe un chemin de s à t . On note $|X| = n$ et $|E| = m$

Il existe des algorithmes déterministes (programmation dynamique notamment) de complexité $\mathcal{O}(m + n)$ en temps, mais $\mathcal{O}(n)$ en espace, ce qui peut poser problème si le graphe est trop gros (graphe d'Internet par exemple). On cherche ici un algorithme plus lent, mais moins gourmand en mémoire.

Théorème 3.6. *Il existe un algorithme probabiliste de type one-sided error répondant à ce problème en $\mathcal{O}(mn)$ en temps et $\mathcal{O}(1)$ en espace.*

Preuve: Considérons l'algorithme de marche aléatoire suivant :

ALGORITHME

1. $u \leftarrow s$
2. Itérer tant que $u \neq t$
 - Soit v voisin aléatoire de u (choisi uniformément)
 - $u \leftarrow v$
3. Déclarer G S-T CONNEXE

* La complexité en espace est évidente.

* Si G n'est pas S-T CONNEXE, alors l'algorithme ne termine clairement pas.

* Reste à montrer la complexité en temps dans le cas où G est S-T CONNEXE.

Notons, pour tous sommets (i, j) dans la composante connexe de s , $h_{i,j}$ le nombre moyen d'étapes de la marche aléatoire pour aller de i à j ; et $C(G)$ le maximum pour $v \in X$ du temps moyen pour passer par tous les sommets de G en partant de v .

Remarquons qu'il existe un chemin $\tau = u_1 u_2 \dots u_p$ de s à t de longueur majorée par $2n$: il suffit en effet de construire un arbre couvrant de la composante connexe de s et de le parcourir en profondeur.

On note un chemin $\sigma \geq \tau$ si τ est une sous-séquence de σ ; $C(G)$ est clairement majoré par le nombre d'étapes qu'il faut pour construire un chemin $\sigma \geq \tau$, donc par

$$C(G) \leq h_{u_1, u_2} + h_{u_2, u_3} + \dots + h_{u_{p-1}, u_p}$$

Comme la somme ci-dessus comporte au plus $2n$ termes, et que chacun est majoré par $2m$ d'après le lemme 3.7 ci-dessous, on obtient bien une complexité en $4nm = \mathcal{O}(mn)$.

□

Lemme 3.7. *Avec les notations de la preuve du théorème,*

i .

$$\forall i \in X, h_{i,i} = \frac{2m}{d(i)}$$

où $d(i)$ est le degré de i dans G , ie son nombre de voisins immédiats

ii . $\forall (i, j) \in X^2$,

$$(i, j) \in E^2 \Rightarrow h_{i,j} \leq 2m - 1$$

Preuve: i . Le premier point est plus ou moins admis, mais on peut s'en convaincre par les arguments suivants : on formalise la marche aléatoire de l'algorithme par une chaîne de Markov de matrice de transition $P = (P_{i,j})_{(i,j) \in X^2} \in \mathcal{M}_n(\mathbb{R})$ où

$$\forall (i, j) \in X^2, P_{i,j} = \begin{cases} \frac{1}{d(i)} & \text{si } (i, j) \in E \\ 0 & \text{sinon} \end{cases}$$

Notons par ailleurs $X^k = (X_i^k)_{i \in X} \in \mathbb{R}^n$ le vecteur de probabilité d'état après la k -ième étape de marche aléatoire (ie pour tout sommet i , la probabilité de se trouver en i après k étapes vaut X_i^k), on a par définition

$$X^{k+1} = X^k P$$

On admet que si G est connexe (et sinon on peut simplement considérer la composante connexe de s), il existe une unique distribution stationnaire Π vérifiant

$$\Pi P = \Pi$$

et on vérifie facilement par le calcul que la distribution Π est telle que

$$\forall i \in X, \Pi_i = \frac{d(i)}{2m}$$

Comme $X^k \xrightarrow[k \rightarrow +\infty]{} \Pi$ (là encore, admis...), le lemme 3.8 nous convainc que pour tout sommet i , $h_{i,i} = \frac{1}{\Pi_i} = \frac{2m}{d(i)}$

ii . Soient deux sommets i et j tels que $(i, j) \in E$, remarquons que

$$\begin{aligned} h_{j,j} &= \sum_{k/(k,j) \in E} \mathbb{E}(\text{nombre d'étapes pour aller de } k \text{ à } j \mid \text{la première étape en} \\ &\quad \text{partant de } j \text{ va en } k) \\ &= \frac{1}{d(j)} \sum_{k/(k,j) \in E} (1 + h_{k,j}) \end{aligned}$$

En particulier,

$$\frac{2m}{d(j)} = h_{j,j} \geq \frac{1}{d(j)} (1 + h_{i,j})$$

d'où

$$h_{i,j} \leq 2m - 1$$

□

3.3.2 Exercices : exemples

1. Si G est complet, le résultat ci-dessus donne

$$C(G) \leq 2n^3$$

mais on peut obtenir beaucoup mieux : partons d'un sommet quelconque, et pour tout $i \in \llbracket 1; n \rrbracket$, notons X_i la première étape où i sommets différents ont été visités. On cherche à calculer $C(G) = \mathbb{E}(X_n)$. Remarquons que $T_k := X_{k+1} - X_k$ suit une loi géométrique de paramètre $\frac{k}{n}$, et vérifie donc

$$\mathbb{E}(T_k) = \frac{n}{n-k}$$

Sommons

$$\begin{aligned} \mathbb{E}(X_n) &= \mathbb{E}(X_1) + \sum_{k=1}^{n-1} \mathbb{E}(T_k) \\ &= N \left(\sum_{k=1}^n \frac{1}{k} \right) \end{aligned}$$

On retrouve la série harmonique, d'où


$$C(G) \sim n \ln n$$

2. Montrer qu'il existe un graphe orienté G tel que $C(G) \geq 2^n$.

Considérons le graphe $G = (X, V)$ défini par

$$\begin{cases} V = \llbracket 1; n \rrbracket \\ \forall i \in \llbracket 1; n-1 \rrbracket, (i, i+1) \in V \\ \forall j \in \llbracket 1; n-1 \rrbracket, (j, 1) \in V \end{cases}$$

soit



En partant de 1, on voit que $C(G) = 2^n$

3. *Jeu du chat et de la souris* :

Soient un chat et une souris qui se déplacent de manière synchrone sur un graphe G . Montrer que le nombre moyen d'étapes avant qu'ils ne se rencontrent est majoré par $4nm^2$.

Considérons le graphe produit $G' = G \times G$, qui a n^2 sommets et m^2 arêtes ; on cherche à savoir quand on passera sur un sommet du type (x, x) . Il y a donc n sommets "gagnants", et d'après le théorème précédent, le nombre moyen d'étapes est majoré par

$$\frac{1}{n}4n^2m^2 = 4nm^2$$

Retour sur un résultat courant

Lemme 3.8. Soit $(X_i)_{i \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes identiquement distribuées selon la loi $\mathbb{P}(X_i = 1) = p = 1 - \mathbb{P}(X_i = 0)$.

Notons $T = \min(i \in \mathbb{N}^* / X_i = 1)$. On a

$$\mathbb{E}(T) = \frac{1}{p}$$

Preuve: Calculons

$$\forall k \in \mathbb{N}^*, \mathbb{P}(T = k) = (1 - p)^{k-1} p$$

d'où

$$\begin{aligned} \mathbb{E}(T) &= \sum_{k \in \mathbb{N}^*} k \mathbb{P}(T = k) \\ &= p \sum_{k \in \mathbb{N}^*} k (1 - p)^{k-1} \\ &= \frac{p}{(1 - (1 - p))^2} \\ &= \frac{1}{p} \end{aligned}$$

□