

Algorithmique avancée: Algorithmes probabilistes

Serge Haddad

LMF, ENS Paris-Saclay & CNRS & INRIA

L3 et M2 FESUP Informatique

- 1 Introduction
- 2 Structures de données dynamiques
- 3 Dérandomisation
- 4 Approximation probabiliste
- 5 Algorithmes de Monte Carlo et de Las Vegas

Plan

1 Introduction

Structures de données dynamiques

Dérandomisation

Approximation probabiliste

Algorithmes de Monte Carlo et de Las Vegas

Algorithmes probabilistes

On considère une instruction probabiliste $\text{Sample}(\text{set}, \text{dist})$ où :

- ▶ set est un ensemble fini ;
- ▶ dist est une distribution sur set ;
- ▶ $\text{Sample}(\text{set}, \text{dist})$ renvoie un élément de set tiré aléatoirement selon dist.

La complexité de cette instruction est proportionnelle à $\log(|\text{set}|)$
(peut être améliorée en cas d'échantillonnages répétés)

Lorsqu'un algorithme contient des instructions probabilistes

- ▶ le résultat de l'algorithme est une variable aléatoire ;
- ▶ pour une entrée donnée, le temps d'exécution est une variable aléatoire.

Comment définir la correction et la complexité ?

Terminaison

Terminaison standard

Pour toute exécution, l'algorithme se termine.

Terminaison probabiliste

L'algorithme se termine presque sûrement (i.e. avec probabilité 1).

Correction : cas général

Correction standard

- ▶ Soit $out(in)$ le résultat attendu ;
- ▶ Soit $output(in)$ le résultat aléatoire de l'algorithme.

Pour tout in , $output(in) = out(in)$.

Correction p -probabiliste

- ▶ Soit $out(in)$ le résultat attendu ;
- ▶ Soit $output(in)$ le résultat aléatoire de l'algorithme.

Pour tout in , $\Pr(output(in) = out(in)) \geq p$.

Monte Carlo et Las Vegas

Un algorithme de Monte Carlo est :

- ▶ un algorithme qui se termine toujours ;
- ▶ et garantit une correction probabiliste.

Un algorithme de Las Vegas est :

- ▶ un algorithme qui se termine presque sûrement ;
- ▶ et garantit une correction standard.

Un algorithme de Monte Carlo qui renvoie soit le résultat correct soit « échec » peut-être transformé en algorithme de Las Vegas en l'itérant jusqu'à obtenir le résultat correct.

Correction : cas spécifiques

Problèmes d'optimisation

- ▶ Soit $Sol(in)$ un ensemble de solutions ;
- ▶ Soit f qui associe à tout $x \in Sol(in)$, une récompense positive ;
- ▶ Soit $out(in) = \sup(f(x) \mid x \in Sol(in))$;
- ▶ Soit $0 < c < 1$ une garantie de performance fixe.

Pour tout in , $output(in) \in Sol(in)$ et $\mathbf{E}(f(output(in))) \geq c \cdot out(in)$.

Problèmes d'approximation

- ▶ Soit $out(in)$ une valeur numérique positive ;
- ▶ Soit $0 < \varepsilon, \delta < 1$ des garanties de performance, entrées de l'algorithme.

Pour tout in , $\mathbf{Pr}(|output(in) - out(in)| > \varepsilon \cdot out(in)) < \delta$.

Complexité

Soit $T(in)$ le temps d'exécution aléatoire.

Soit n une taille d'entrée, on note $T(n) = \max(T(in) \mid |in| = n)$.

Soit f une fonction de \mathbb{N} dans \mathbb{R}_+ .

Complexité en moyenne.

$$\mathbf{E}(T(n)) \in O(f(n))$$

Complexité au pire cas probabiliste.

$$\exists c > 0 \lim_{n \rightarrow \infty} \mathbf{Pr}(T(n) > c \cdot f(n)) = 0$$

Aucune des deux notions n'implique l'autre !

Tri rapide probabiliste

TriRapide(T, ℓ, h)

If $h \leq \ell$ **then return**

$i \leftarrow \text{Sample}(\text{uniform}, \ell \dots h)$; $\text{Swap}(i, h)$; $deb \leftarrow \ell - 1$

For j **from** ℓ **to** $h - 1$ **do**

If $(T[j], j) < (T[h], i)$ **then**

$deb \leftarrow deb + 1$

$\text{Swap}(deb, j)$

$deb \leftarrow deb + 1$; $\text{Swap}(deb, h)$

 TriRapide($T, \ell, deb - 1$)

 TriRapide($T, deb + 1, h$)

Soit $Time(n)$, la complexité aléatoire du tri rapide d'un tableau de taille n .

- ▶ $Time(0) = Time(1) = 1$;
- ▶ pour $n \geq 2$, $\mathbf{E}(Time(n)) \leq 4n + \frac{1}{n} \sum_{0 \leq i \leq n-1} \mathbf{E}(Time(i)) + \mathbf{E}(Time(n-1-i))$.

Analyse de complexité

Soit $C(n)$ défini par :

- ▶ $C(0) = C(1) = 1$;
- ▶ pour $n \geq 2$, $C(n) = 4n + \frac{1}{n} \sum_{0 \leq i \leq n-1} C(i) + C(n-1-i)$.

Alors $C(n) = O(n \log(n))$.

Preuve.

$$nC(n) = 4n^2 + 2 \sum_{i=0}^{n-1} C(i) \text{ et } (n-1)C(n-1) = 4(n-1)^2 + 2 \sum_{i=0}^{n-2} C(i).$$

$$\text{D'où } nC(n) - (n-1)C(n-1) = 4(2n-1) + 2C(n-1)$$

$$\text{Puis } nC(n) = (n+1)C(n-1) + 4(2n-1).$$

$$\begin{aligned} \frac{C(n)}{n+1} &= \frac{C(n-1)}{n} + \frac{4(2n-1)}{n(n+1)} \leq \frac{C(n-1)}{n} + \frac{8}{n+1} \\ &\leq \frac{C(n-2)}{n-1} + \frac{8}{n} + \frac{8}{n+1} \\ &\vdots \\ &\leq \frac{C(1)}{2} + \sum_{i=2}^n \frac{8}{i+1} = O(\log(n)) \end{aligned}$$

Intérêt des algorithmes probabilistes

- Conception plus simple.
- Combiné avec la technique de dérandomisation fournit des algorithmes déterministes.
- Analyse de complexité indépendante d'hypothèses sur les données.
- Permet une analyse de complexité intermédiaire entre la complexité en moyenne et la complexité au pire cas.

Plan

Introduction

2 Structures de données dynamiques

Dérandomisation

Approximation probabiliste

Algorithmes de Monte Carlo et de Las Vegas

Dictionnaire

Un dictionnaire est un ensemble d'enregistrements.

Chaque enregistrement est un couple (clé,valeur).

L'espace des clés est ordonné et de taille trop importante pour indiquer un tableau en mémoire.

Les opérations usuelles sont :

- ▶ Insérer(clé,valeur) qui insère un enregistrement si la clé n'est pas déjà présente ;
- ▶ Modifier(clé,valeur) qui modifie la valeur d'un enregistrement si la clé est présente ;
- ▶ Supprimer(clé) qui supprime un enregistrement si la clé est présente ;
- ▶ Chercher(clé) qui renvoie la valeur d'un enregistrement si la clé est présente.

La complexité de Modifier est essentiellement celle de Chercher.

Implémentation d'un dictionnaire

La structure de données doit être *dynamique*.

Les structures usuelles.

- ▶ Un tableau qu'on recopie dans un tableau plus grand (resp. plus petit) en cas de débordement (resp. sur-allocation) ;
- ▶ Une liste simplement ou doublement chaînée, linéaire ou circulaire, etc. ;
- ▶ Un arbre binaire de recherche *équilibré* ;
- ▶ **Une table de hachage** : un tableau de listes dont la fonction de hachage appliquée à la clé fournit l'entrée dans la table.
- ▶ **Une structure à trous.**


On étudiera la complexité des opérations en fonction de n , le nombre courant d'enregistrements.

Table de hachage

Une table T de taille m de listes et h une fonction des clés dans $\{0, \dots, m - 1\}$.

Insertion de c : parcours de la liste $T[h(c)]$ et insertion de c si absente.

Illustration : $m = 4$ et $h(c) = c \bmod 4$.



Complexité de la recherche.

- ▶ au pire, les n clés sont rangées dans la même liste d'où $O(n)$.
- ▶ en moyenne,
 - ▶ *hypothèses* : $|h^{-1}(i)|$ indépendant de i et clés tirées uniformément ;
 - ▶ *conclusion* : la longueur moyenne des listes est $\frac{n}{m}$;
 - ▶ d'où une complexité moyenne en $O(1)$ si $m = \Omega(n)$.

Dictionnaire statique

Dans un dictionnaire *statique* les mises à jours sont rares. Par exemple :

- ▶ des catalogues de produits ;
- ▶ des dictionnaires de langue ;
- ▶ l'ensemble des mots réservés d'un langage de programmation.

Une *collision* de h est un ensemble $\{x, x'\}$ tel que $h(x) = h(x')$.

Intérêt de rechercher une fonction de hachage qui ne provoque pas de collisions.

Hypothèses.

- ▶ Les indices de la table sont $\{0, \dots, m - 1\}$;
- ▶ Les n clés appartiennent à $\{0, \dots, p - 1\}$ avec p premier ;
- ▶ L'espace des fonctions de hachage est :

$$H = \{h_{a,b}(x) = (ax + b \bmod p) \bmod m \mid 0 < a < p \wedge 0 \leq b < p\}$$

d'où $|H| = p(p - 1)$.

Un choix approprié de m

On note $nbcoll$ la somme des collisions pour tous les $h \in H$.

$$nbcoll = \frac{1}{2} \sum_{a,b} |\{(x, x') \mid x \neq x' \wedge h_{a,b}(x) = h_{a,b}(x')\}|$$

$nbcoll$ vérifie la majoration suivante :

$$nbcoll \leq \frac{n(n-1)}{2} \cdot \frac{p(p-1)}{m}$$

Par conséquent, si $m = n^2$,

plus de la moitié des fonctions ne provoquent pas de collisions.

Monte Carlo. On tire aléatoirement une fonction de hachage et avec probabilité supérieure ou égale à $\frac{1}{2}$, on n'a pas de collision.

Las Vegas. Avec en moyenne deux tirages aléatoires, on trouve une fonction de hachage sans collision.

Preuve de la majoration

On note $+_p, \times_p$ les opérations modulo p

et $\mathbb{Z}/p\mathbb{Z}$ l'ensemble $\{0, \dots, p-1\}$ doté de ces opérations (un corps).

Soit $\tilde{h}_{a,b}(x) = a \times_p x +_p b$.

1. $\tilde{h}_{a,b}$ est bijective.
2. Pour tout $y \neq y'$ et $x \neq x'$, il existe une et une seule paire (a, b) telle que $y = \tilde{h}_{a,b}(x)$ et $y' = \tilde{h}_{a,b}(x')$.

$$nbcoll = \frac{1}{2} \sum_{a,b} |\{(x, x') \mid x \neq x' \wedge h_{a,b}(x) = h_{a,b}(x')\}|$$

Soit $x \neq x'$. $h_{a,b}(x) = h_{a,b}(x') \Leftrightarrow \tilde{h}_{a,b}(x) = \tilde{h}_{a,b}(x') \pmod{m}$.

D'après la propriété 1, $\tilde{h}_{a,b}(x) \neq \tilde{h}_{a,b}(x')$. D'où :

$$nbcoll = \frac{1}{2} \sum_{a,b} \sum_{y \neq y'} |\{(x, x') \mid x \neq x' \wedge y = y' \pmod{m} \wedge y = \tilde{h}_{a,b}(x) \wedge y' = \tilde{h}_{a,b}(x')\}|$$

D'après la propriété 2, $nbcoll = \frac{n(n-1)}{2} \sum_{y \neq y'} |\{(y, y') \mid y = y' \pmod{m}\}|$.

Il y a au plus $p(\lceil \frac{p}{m} \rceil - 1) \leq p(\frac{p+m-1}{m} - 1) = \frac{p(p-1)}{m}$ paires (y, y')

avec $y \neq y'$ telles que $y = y' \pmod{m}$.

Une autre majoration

Soit $H' \subseteq H$ l'ensemble des fonctions de hachage qui provoquent au moins n collisions.

$$\text{Si } m = n \text{ alors } |H'| < \frac{|H|}{2}$$

Preuve.

$$n|H'| \leq nbcoll \leq \frac{n(n-1)}{2} \cdot \frac{p(p-1)}{n}$$


D'où :

$$|H'| \leq \frac{n(n-1)}{2n^2} \cdot p(p-1) < \frac{|H|}{2}$$

Double hachage

Dans une table de double hachage T ,

- ▶ chaque entrée i pointe sur une table de hachage T_i de taille m_i ;
- ▶ dont les entrées sont calculées par la fonction h_i .



Las Vegas. On choisit $m = n$ et aléatoirement une fonction $h \in H \setminus H'$.

Soit n_i le nombre de clés x telles que $h(x) = n_i$, on choisit :

- ▶ $m_i = \max(1, n_i^2)$;
- ▶ aléatoirement h_i une fonction sans collisions entre les n_i clés.

Complexité du double hachage

Complexité spatiale.

La table primaire occupe n cellules et les tables secondaires occupent :

$$\begin{aligned} \sum_{i=1}^n \max(n_i^2, 1) &\leq \sum_{i=1}^n (n_i^2 + 1) = n + \sum_{i=1}^n n_i + \sum_{i=1}^n n_i(n_i - 1) \\ &= 2n + \sum_{i=1}^n n_i(n_i - 1) < 2n + 2n = 4n \end{aligned}$$

Complexité temporelle.

La génération aléatoire d'une fonction de hachage s'effectue en $O(1)$.

Chaque fonction est trouvée après $O(1)$ essais en moyenne.


La vérification du nombre de collisions des fonctions de hachage s'effectue en $O(n)$.

Structure à trous

Une structure à trous est constituée de listes doublement chaînées.

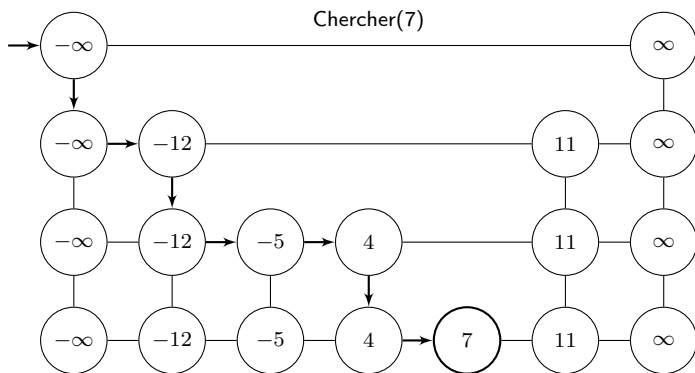
- ▶ Chaque liste contient un sous-ensemble des clés triées par ordre croissant et les bornes $-\infty$ et ∞ ;
- ▶ Les listes sont ordonnées verticalement ;
- ▶ La liste *basse* contient toutes les clés ;
- ▶ Chaque autre liste contient un sous-ensemble (non strict) des clés de la liste immédiatement en dessous ;
- ▶ Chaque clé de cette autre liste est doublement chaînée à la même clé de la liste immédiatement en dessous ;
- ▶ La liste *haute* est l'unique liste qui ne contient que les bornes $-\infty$ et ∞ ;
- ▶ On *entre* dans la structure à trous par la clé $-\infty$ de la liste haute.

Illustration



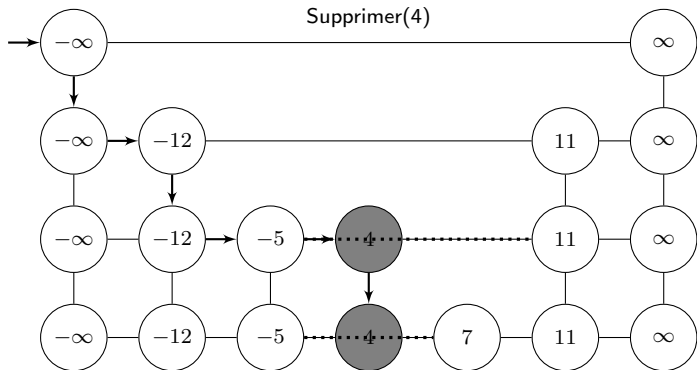
Recherche

On avance dans la liste courante sans dépasser la clé cherchée
et on descend dans la liste suivante
jusqu'à ce qu'on atteigne la liste basse.



Suppression

On cherche la clé puis on supprime ses occurrences en descendant dans les listes et en supprimant chaque liste réduite à ses bornes.

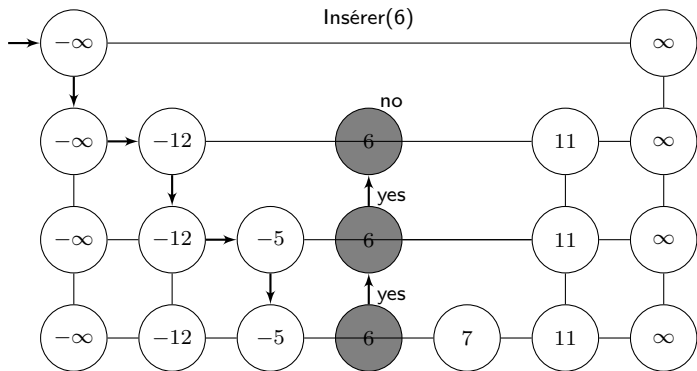


Insertion (probabiliste)

On cherche la clé puis on l'insère dans la liste basse

et itérativement avec probabilité $\frac{1}{2}$ on l'insère dans la liste au dessus.

en ajoutant une liste à chaque tirage positif lorsqu'on atteint la liste haute.



Nombre de listes

Rappels probabilistes.

- Inégalité 'union-somme' : $\Pr(\bigcup_{i=1}^n E_i) \leq \sum_{i=1}^n \Pr(E_i)$
- Inégalité 'au moins un' : $\Pr(\sum_{i=1}^n X_i \geq k) \leq \Pr(\bigvee_{i=1}^n X_i \geq \frac{k}{n}) \leq \sum_{i=1}^n \Pr(X_i \geq \frac{k}{n})$

Soit H la variable aléatoire associée au nombre de listes.

Dans une structure à trous de $n > 0$ clés on a :

$$\Pr(H \geq 3 \log(n) + 2) \leq \frac{1}{n^2}$$

Preuve

Il y a au moins $h + 2$ listes ssi une clé a été dupliquée au moins h fois.

Par l'inégalité 'union-somme', $\Pr(H \geq h + 2) \leq n2^{-h}$.

Par conséquent, $\Pr(H \geq 3 \log(n) + 2) \leq n2^{-3 \log(n)} = \frac{1}{n^2}$. □

On note R la variable aléatoire associée au nombre de parcours de pointeurs lors d'une recherche.

Pire cas probabiliste d'une recherche (1)

$$\text{Si } n > 0 \text{ alors } \Pr(R > \log(n)(12 \log(n) + 8)) \leq \frac{3 \log(n) + 3}{n^2}$$

Preuve. Soit N_i le nombre de parcours de pointeurs horizontaux de la liste i .

$$\begin{aligned} & \Pr(R > \log(n)(12 \log(n) + 8)) \\ &= \Pr\left(\sum_{1 \leq i} \mathbf{1}_{H \geq i}(1 + N_i) > \log(n)(12 \log(n) + 8)\right) \\ &\leq \Pr\left(\sum_{1 \leq i \leq 3 \log(n) + 2} (1 + N_i) + \sum_{3 \log(n) + 2 < i} \mathbf{1}_{H \geq i}(1 + N_i) > \log(n)(12 \log(n) + 8)\right) \\ &\leq \Pr\left(\sum_{1 \leq i \leq 3 \log(n) + 2} (1 + N_i) > \log(n)(6 \log(n) + 4)\right) \\ &\quad + \Pr\left(\sum_{3 \log(n) + 2 < i} \mathbf{1}_{H \geq i}(1 + N_i) > \log(n)(6 \log(n) + 4)\right) \\ &\leq \Pr\left(\sum_{1 \leq i \leq 3 \log(n) + 2} (1 + N_i) > \log(n)(6 \log(n) + 4)\right) + \Pr(H > 3 \log(n) + 2) \\ &\leq \sum_{1 \leq i \leq 3 \log(n) + 2} \Pr(1 + N_i > 2 \log(n)) + \frac{1}{n^2} \end{aligned}$$

Pire cas probabiliste d'une recherche (2)

- Soit $e \neq -\infty$ de la liste i , un élément du parcours
l'élément précédent du parcours est
 - ▶ soit un certain $e' < e$ dans la liste i ;
 - ▶ soit e dans la liste $i + 1$.

Le deuxième cas intervient avec une probabilité $\frac{1}{2}$, d'après l'insertion.

- Si $e = -\infty$, ce cas a une probabilité égale à 1.

Par conséquent, N_i vérifie $\Pr(N_i \geq m) \leq 2^{-m}$. D'où :

$$\Pr(1 + N_i > 2 \log(n)) \leq \frac{1}{2^{2 \log(n)}} = \frac{1}{n^2}$$

et en reportant dans l'inéquation :

$$\Pr(R > \log(n)(12 \log(n) + 8)) \leq \frac{3 \log(n) + 2}{n^2} + \frac{1}{n^2}$$

Cas moyen d'une recherche

Si $n > 0$ alors $\mathbf{E}(R) \leq 6 \log(n) + 6$

Preuve. Le nombre de parcours de pointeurs horizontaux est $\leq n$.

$$\begin{aligned}\mathbf{E}(R) &= \mathbf{E} \left(\sum_{1 \leq i} \mathbf{1}_{H \geq i} (1 + N_i) \right) \\ &\leq \sum_{1 \leq i \leq 3 \log(n) + 2} \mathbf{E}(1 + N_i) + n \Pr(H > 3 \log(n) + 2) + \sum_{3 \log(n) + 2 < i} \Pr(H \geq i) \\ &\leq \sum_{1 \leq i \leq 3 \log(n) + 2} \mathbf{E}(1 + N_i) + 1 + \sum_{3 \log(n) + 2 < i} \frac{1}{i^2} \\ &\leq \sum_{1 \leq i \leq 3 \log(n) + 2} \mathbf{E}(1 + N_i) + 2 \\ &\leq 6 \log(n) + 6\end{aligned}$$

car $\mathbf{E}(1 + N_i) \leq 2$

Suppression et insertion

Le surcoût de l'insertion et de la suppression est lié au tirage répété d'une pièce non biaisée et au nombre d'éléments ajoutés.

D'où :

Cas moyen.

Le nombre moyen d'éléments ajoutés est 2.

Pire cas probabiliste.

La probabilité que ce nombre soit supérieur ou égal à $\log(n)$ est inférieure ou égale à $\frac{1}{n}$.

Plan

Introduction

Structures de données dynamiques

3 Dérandomisation

Approximation probabiliste

Algorithmes de Monte Carlo et de Las Vegas

Le problème de la coupe maximale

Etant donné un graphe $G = (V, E)$, le problème de la coupe maximale consiste à :

- ▶ renvoyer une partition $V = V_0 \uplus V_1$
- ▶ telle que $|\{\{u, v\} \in E \mid u \in V_0 \wedge v \in V_1\}|$ soit maximal.

Le problème de décision associé MAXCUT prend en entrée G et $K \leq |E|$ et renvoie vrai si :

- ▶ il existe une partition $V = V_0 \uplus V_1$
- ▶ telle que $|\{\{u, v\} \in E \mid u \in V_0 \wedge v \in V_1\}| \geq K$.

MAXCUT est NP-complet.

Preuve.

Par réduction de 3SAT à MAX2SAT puis de MAX2SAT à MAXCUT.

MAX2SAT est NP-complet (1)

Le problème MAX2SAT prend en entrée un entier k et des clauses d'au plus deux littéraux sur les variables $(x_i)_{i \leq n}$ et renvoie vrai si :

- ▶ il existe une valuation de $(x_i)_{i \leq n}$ dans $\{\perp, \top\}^n$
- ▶ telle qu'au moins k clauses soit satisfaites par cette valuation.

Réduction de 3SAT à MAX2SAT. Soit $\varphi = \bigwedge_{1 \leq i \leq p} a_i \vee b_i \vee c_i$.

L'instance de MAX2SAT **Ins** est définie par $k = 7p$ et pour $\bigcup_{i \leq p} Cl_i$ avec Cl_i l'ensemble des clauses suivantes :

- ▶ a_i, b_i, c_i, d_i ;
- ▶ $\neg a_i \vee \neg b_i, \neg a_i \vee \neg c_i, \neg b_i \vee \neg c_i$;
- ▶ $a_i \vee \neg d_i, b_i \vee \neg d_i, c_i \vee \neg d_i$.

où les d_i sont des nouvelles variables.

MAX2SAT est NP-complet (2)

Considérons une valuation \mathbf{v} des variables de φ .

- Supposons que $\mathbf{v} \models a_i \vee b_i \vee c_i$. Examinons les différents cas de satisfaction :
 - ▶ $a_i = \top$ et $b_i = c_i = \perp$. En choisissant $d_i = \perp$, on satisfait 7 clauses de Cl_i .
En choisissant $d_i = \top$, on satisfait 6 clauses de Cl_i .
 - ▶ $a_i = b_i = \top$ et $c_i = \perp$.
En choisissant $d_i \in \{\perp, \top\}$, on satisfait 7 clauses de Cl_i .
 - ▶ $a_i = b_i = c_i = \top$. En choisissant $d_i = \perp$, on satisfait 6 clauses de Cl_i .
En choisissant $d_i = \top$, on satisfait 7 clauses de Cl_i .
- Supposons que $\mathbf{v} \not\models a_i \vee b_i \vee c_i$. Si $d_i = \top$, on satisfait 4 clauses de Cl_i .
Si $d_i = \perp$, on satisfait 6 clauses de Cl_i .
- Supposons que φ est satisfaisable.
Par un bon choix de valuation pour les d_i , on satisfait $7p$ clauses de **Ins**.
- Supposons que φ n'est pas satisfaisable.
Alors pour tout \mathbf{v} , il existe i tel que $\mathbf{v} \not\models a_i \vee b_i \vee c_i$.
Il n'est donc pas possible satisfaire $7p$ clauses de **Ins**.

MAXCUT est NP-complet (1)

Réduction de MAX2SAT à MAXCUT. En préalable :

- Elimination des clauses unitaires.
 - ▶ Ajout d'une nouvelle variable y ;
 - ▶ Remplacement d'une clause a par $a \vee y$ et $a \vee \neg y$ puis incrémentation du seuil.
- Suppression des clauses redondantes $x \vee \neg x$ et décrémentation du seuil.

Soit une instance **Ins** de MAX2SAT définie par :

les variables $\{x_i\}_{i \leq n}$, les clauses $\{a_j \vee b_j\}_{1 \leq j \leq p}$ et $k \leq p$.

Le graphe $G_{\text{Ins}} = (V, E_1 \uplus E_2)$ est défini par :

- ▶ $V = \{\perp\} \cup \{x_i^j, \bar{x}_i^j\}_{1 \leq i \leq n, 0 \leq j \leq 2p}$;
- ▶ $E_1 = \{\{x_i^j, \bar{x}_i^{j'}\}\}_{1 \leq i \leq n, 0 \leq j, j' \leq 2p}$ ($|E_1| = n(2p + 1)^2$) ;
- ▶ $E_2 = \bigcup_{1 \leq j \leq p} Tr_j$ avec $Tr_j = \{\{a_j^{2j-1}, b_j^{2j}\}, \{a_j^{2j-1}, \perp\}, \{b_j^{2j}, \perp\}\}$
et $\neg x$ identifié à \bar{x} .

$$K = |E_1| + 2k.$$

MAXCUT est NP-complet (2)

Soit $V = V_0 \uplus V_1$ et $CUT = \{\{u, v\} \mid u \in V_0 \wedge v \in V_1\}$.

Observations.

- ▶ S'il existe $x_i^j \in V_0$ et $x_i^{j'} \in V_1$ alors $|E_1 \setminus CUT| \geq 2p + 1$;
 - ▶ S'il existe $\bar{x}_i^j \in V_0$ et $\bar{x}_i^{j'} \in V_1$ alors $|E_1 \setminus CUT| \geq 2p + 1$;
 - ▶ S'il existe m et i tel que $\bigcup_{j \leq 2p} \{x_i^j, \bar{x}_i^j\} \subseteq V_m$ alors $|E_1 \setminus CUT| \geq (2p + 1)^2$.
- Supposons que $|CUT| \geq K$. Alors :
 - ▶ pour tout i , il existe m_i tel que $\{x_i^j\}_{j \leq 2p} \subseteq V_{m_i}$ et $\{\bar{x}_i^j\}_{j \leq 2p} \subseteq V_{1-m_i}$;
 - ▶ $|\{j \mid |Tr_j \cap CUT| = 2\}| \geq k$.

On définit la valuation \mathbf{v} par $\mathbf{v}(x_i) = \top$ ssi $\perp \notin V_{m_i}$.

- Supposons qu'une valuation \mathbf{v} satisfasse au moins k clauses. Alors :

$V_1 = \{x_i^j \mid i \leq n \wedge j \leq 2p+1 \wedge \mathbf{v}(x_i) = \top\} \cup \{\bar{x}_i^j \mid i \leq n \wedge j \leq 2p+1 \wedge \mathbf{v}(x_i) = \perp\}$
et $V_0 = V \setminus V_1$.

Un algorithme probabiliste naïf

On note $V = \{v_i\}_{i \leq n}$.

$V_0 \leftarrow \emptyset$

$V_1 \leftarrow \emptyset$

$Cut \leftarrow \emptyset$

For i from 1 do n do

$b \leftarrow \text{Sample}(\{\perp, \top\}, \text{uniform})$

If b then

$V_0 \leftarrow V_0 \cup \{v_i\}$

Else

$V_1 \leftarrow V_1 \cup \{v_i\}$

For $\{u, v\} \in E$ do

If $\{u, v\} \cap V_0 \neq \emptyset$ **and** $\{u, v\} \cap V_1 \neq \emptyset$ **then**

$Cut \leftarrow Cut \cup \{\{u, v\}\}$

Garantie probabiliste

Cut est une variable aléatoire.

Introduisons pour chaque $i \leq n$, X_i définie par : $X_i = m$ si $v_i \in V_m$.

Observons que $|Cut| = \sum_{\{v_i, v_j\} \in E} \mathbf{1}_{X_i \neq X_j}$. D'où :

$$\begin{aligned} \mathbf{E}(|Cut|) &= \sum_{\{v_i, v_j\} \in E} \mathbf{Pr}(X_i \neq X_j) \\ &= \sum_{\{v_i, v_j\} \in E} \mathbf{Pr}(X_i = 0 \neq X_j) + \mathbf{Pr}(X_i = 1 \neq X_j) \\ &= \sum_{\{v_i, v_j\} \in E} \frac{1}{4} + \frac{1}{4} \end{aligned}$$

D'où :

$$\mathbf{E}(|Cut|) = \frac{|E|}{2}$$

Dérandomisation de l'algorithme (1)

Abrégeons l'événement $\bigwedge_{i \leq k} X_i = x_i$ par $(x_i)_{i \leq k}$.

$$\begin{aligned} \mathbf{E}(|Cut| \mid (x_i)_{i \leq k}) &= \sum_{i \in \mathbb{N}} i \Pr(|Cut| = i \mid (x_i)_{i \leq k}) \\ &= \sum_{i \in \mathbb{N}} \frac{i \Pr(|Cut| = i \wedge (x_i)_{i \leq k})}{\Pr((x_i)_{i \leq k})} \\ &= \sum_{i \in \mathbb{N}} \frac{i \Pr(|Cut| = i \wedge (x_i)_{i \leq k} \wedge X_{k+1} = 0) + i \Pr(|Cut| = i \wedge (x_i)_{i \leq k} \wedge X_{k+1} = 1)}{\Pr((x_i)_{i \leq k})} \\ &= \Pr(X_{k+1} = 0 \mid (x_i)_{i \leq k}) \mathbf{E}(|Cut| \mid (x_i)_{i \leq k} \wedge X_{k+1} = 0) \\ &\quad + \Pr(X_{k+1} = 1 \mid (x_i)_{i \leq k}) \mathbf{E}(|Cut| \mid (x_i)_{i \leq k} \wedge X_{k+1} = 1) \\ &= \frac{1}{2} (\mathbf{E}(|Cut| \mid (x_i)_{i \leq k} \wedge X_{k+1} = 0) + \mathbf{E}(|Cut| \mid (x_i)_{i \leq k} \wedge X_{k+1} = 1)) \end{aligned}$$

Par conséquent, il existe une suite $(x_i)_{i \leq n}$ telle que :

$$\frac{1}{2}|E| = \mathbf{E}(|Cut|) = \mathbf{E}(|Cut| \mid (x_1)) \leq \mathbf{E}(|Cut| \mid (x_i)_{i \leq 2}) \leq \dots \leq \mathbf{E}(|Cut| \mid (x_i)_{i \leq n})$$

Comment la trouver (itérativement) ?

Dérandomisation de l'algorithme (2)

$$\begin{aligned} \mathbf{E}(|Cut| \mid (x_i)_{i \leq k}) \wedge X_{k+1} = m) &= \sum_{\{v_i, v_j\} \in E \wedge i, j \leq k} \mathbf{1}_{x_i \neq x_j} \\ &+ \sum_{\{v_i, v_{k+1} \wedge i \leq k\} \in E \wedge i, j \leq k} \mathbf{1}_{x_i \neq m} \\ &+ \sum_{\{v_i, v_j\} \in E \wedge i \leq k \wedge j > k+1} \Pr(x_i \neq X_j) \\ &+ \sum_{\{v_{k+1}, v_j\} \in E \wedge j > k+1} \Pr(m \neq X_j) \\ &+ \sum_{\{v_i, v_j\} \in E \wedge i, j > k+1} \Pr(X_i \neq X_j) \\ &= \sum_{\{v_i, v_j\} \in E \wedge i, j \leq k} \mathbf{1}_{x_i \neq x_j} + \sum_{\{v_i, v_{k+1}\} \in E \wedge i \leq k} \mathbf{1}_{x_i \neq m} + \sum_{\{v_i, v_j\} \in E \wedge j > k+1} \frac{1}{2} \end{aligned}$$

Par conséquent, $m = \arg \max(\sum_{\{v_i, v_{k+1} \wedge i \leq k\} \in E \wedge i, j \leq k} \mathbf{1}_{x_i \neq m})$.

Un algorithme glouton déterministe

```
 $V_0 \leftarrow \{v_1\}; V_1 \leftarrow \emptyset; Cut \leftarrow \emptyset$   
For  $i$  from 2 do  $n$  do  
   $cnt_0 \leftarrow 0; cnt_1 \leftarrow 0$   
  For  $j$  from 1 do  $i - 1$  do  
    If  $\{v_i, v_j\} \in E$  then  
      If  $v_j \in V_0$  then  $cnt_0 \leftarrow cnt_0 + 1$  else  $cnt_1 \leftarrow cnt_1 + 1$   
    If  $cnt_1 \geq cnt_0$  then  
       $V_0 \leftarrow V_0 \cup \{v_i\}$   
    Else  
       $V_1 \leftarrow V_1 \cup \{v_i\}$   
  For  $\{u, v\} \in E$  do  
    If  $\{u, v\} \cap V_0 \neq \emptyset$  and  $\{u, v\} \cap V_1 \neq \emptyset$  then  
       $Cut \leftarrow Cut \cup \{\{u, v\}\}$ 
```

Cet algorithme garantit $|Cut| \geq \frac{|E|}{2}$.

Plan

Introduction

Structures de données dynamiques

Dérandomisation

4 Approximation probabiliste

Algorithmes de Monte Carlo et de Las Vegas

Bornes de Chernoff-Hoeffding

Soit X_1, \dots, X_n des variables aléatoires indépendantes et $\varepsilon \geq 0$.

On note : $X \stackrel{\text{def}}{=} \sum_{i \leq n} X_i$ et $\mu \stackrel{\text{def}}{=} \mathbf{E}(X)$.

- Bornes multiplicatives

Supposons les X_i à valeurs dans $\{0, 1\}$ et $\varepsilon < 1$. Alors :

$$\mathbf{Pr}(X \geq (1 + \varepsilon)\mu) \leq e^{-\frac{\mu\varepsilon^2}{3}} \text{ et } \mathbf{Pr}(X \leq (1 - \varepsilon)\mu) \leq e^{-\frac{\mu\varepsilon^2}{2}}$$

- Bornes additives

Supposons que pour tout i , $a_i \leq X_i \leq b_i$ avec $a_i < b_i$. Alors :

$$\mathbf{Pr}(X \geq \mu + \varepsilon) \leq e^{-\frac{2\varepsilon^2}{\sum_{i \leq n} (b_i - a_i)^2}} \text{ et } \mathbf{Pr}(X \leq \mu - \varepsilon) \leq e^{-\frac{2\varepsilon^2}{\sum_{i \leq n} (b_i - a_i)^2}}$$

Estimation probabiliste (1)

Soit X une variable aléatoire à valeurs dans $\{0, 1\}$
telle que $0 < p = \Pr(X = 1)$ soit inconnue
mais qu'une borne inférieure $0 < p^* \leq p$ soit connue.

Soit $\varepsilon, \delta > 0$. Alors l'algorithme suivant via les bornes multiplicatives garantit que :

$$\begin{aligned} \Pr\left(\left|p - \frac{\ell}{k}\right| > p\varepsilon\right) &= \Pr(|kp - \ell| > kp\varepsilon) < 2e^{-\frac{\left\lceil \frac{3 \log(2/\delta) \right\rceil p\varepsilon^2}{3}}{p^*}} \\ &\leq 2e^{-\frac{p \log(2/\delta)}{p^*}} \leq 2e^{-\log(2/\delta)} = \delta \end{aligned}$$

```
 $k \leftarrow \left\lceil \frac{3 \log(2/\delta)}{p^* \varepsilon^2} \right\rceil ; \ell \leftarrow 0$ 
```

```
For  $i$  from 1 do  $k$  do
```

```
   $b \leftarrow \text{Sample}(X)$ 
```

```
  If  $b$  then  $\ell \leftarrow \ell + 1$ 
```

```
Return $\left(\frac{\ell}{k}\right)$ 
```

Cet algorithme est polynomial en fonction de $\frac{1}{\varepsilon}$, $\frac{1}{\delta}$ et $\frac{1}{p^*}$.

Estimation probabiliste (2)

Soit $cpt(in)$ un nombre à calculer en fonction d'une entrée in dont un calcul efficace n'est pas connu.

Méthode probabiliste. Définir deux ensembles $E(in) \subset F(in)$ tels que :

- ▶ $|E(in)| = cpt(in)$ et $|F(in)|$ peut être calculé efficacement ;
- ▶ un tirage uniforme de $e \in F(in)$ peut être effectué efficacement ;
- ▶ le test ' $e \in E(in)$?' peut être décidé efficacement ;
- ▶ un minorant de $\frac{|E(in)|}{|F(in)|}$ peut être calculé efficacement.

Solution. On estime la probabilité p que $e \in F(in)$ appartienne à $E(in)$ et on renvoie $p|F(in)|$.

Comptage probabiliste d'interprétations

Soit $\varphi = \bigvee_{i \leq m} Cl_i$ avec $Cl_i = \bigwedge_{j \leq n_i} \ell_j$ où $\ell_j \in \{x_1, \neg x_1, \dots, x_n, \neg x_n\}$.

(sans perte de généralité, pour tout k et i , $x_k, \neg x_k$ n'apparaissent pas simultanément dans Cl_i)

On veut calculer le nombre de valuations $\mathbf{v} \in \{\perp, \top\}^n$ telles que $\mathbf{v} \models \varphi$

Si $P \neq NP$ alors ce calcul ne peut pas s'effectuer en temps polynomial :

Soit ψ une formule CNF alors ψ n'est pas satisfaisable ssi 2^n interprétations satisfont $\neg\psi$ réécrite en temps linéaire en formule DNF.

On cherche alors une estimation probabiliste de ce nombre à l'aide de l'algorithme précédent :

- ▶ Soit la distribution uniforme sur l'ensemble des valuations ;
- ▶ Soit p la probabilité qu'une valuation aléatoire satisfasse φ ;
- ▶ Alors $2^n p$ est le nombre recherché.

Ici $F(in)$ est l'ensemble des valuations.

Problème : soit $p^* = \max_i (2^{-n_i})$ alors $\frac{1}{p^*}$ peut être exponentiel en n .

Un échantillonnage alternatif (1)

Soit $\mathbf{V}_i = \{\mathbf{v} \mid \mathbf{v} \models Cl_i\}$.

- ▶ $|\mathbf{V}_i| = 2^{n-n_i}$;
- ▶ on peut effectuer un tirage uniforme dans \mathbf{V}_i en choisissant de manière équiprobable la valeur d'une variable absente de Cl_i .

Soit $\Omega = \{(i, \mathbf{v}) \mid i \leq m \wedge \mathbf{v} \in \mathbf{V}_i\}$.

- ▶ $|\Omega| = \sum_{i \leq m} |\mathbf{V}_i|$;
- ▶ on peut effectuer un tirage uniforme dans Ω en choisissant $i \leq m$ avec probabilité $\frac{|\mathbf{V}_i|}{|\Omega|}$ puis de manière équiprobable $\mathbf{v} \in \mathbf{V}_i$.

Un échantillonnage alternatif (2)

Soit $\Omega^* \subseteq \Omega$ défini par $\Omega^* = \{(i, \mathbf{v}) \in \Omega \mid \forall j < i (j, \mathbf{v}) \notin \Omega\}$.

Autrement dit, $(i, \mathbf{v}) \in \Omega^*$ si Cl_i est la *première* clause satisfaite par \mathbf{v} .

$|\Omega^*|$ est le nombre de valuations \mathbf{v} telles que $\mathbf{v} \models \varphi$.

On cherche alors une estimation probabiliste de ce nombre à l'aide de l'algorithme précédent :

- ▶ Soit la distribution uniforme sur Ω ;
- ▶ Soit p la probabilité qu'un couple aléatoire (i, \mathbf{v}) appartienne à Ω^* ;
- ▶ Alors $|\Omega|p$ est le nombre recherché.

Avantage : ici $p^* = \frac{1}{m}$ et $\frac{1}{p^*}$ est linéaire en $|\varphi|$.

Plan

Introduction

Structures de données dynamiques

Dérandomisation

Approximation probabiliste

5 Algorithmes de Monte Carlo et de Las Vegas

Calcul du médian : le principe

Soit T un tableau de n éléments tous distincts avec n impair.

On cherche le *médian* m défini par $|\{i \mid T[i] < T[m]\}| = \lfloor \frac{n}{2} \rfloor$.

Il existe un algorithme simple en $O(n \log(n))$ qui consiste à trier T et renvoyer l'élément médian.

Schéma d'un algorithme de Monte Carlo.

- ▶ On sélectionne aléatoirement un sous-ensemble *significatif* R de valeurs de T ;
- ▶ On trie R et on définit un intervalle autour du médian de R ;
- ▶ On sélectionne le sous-ensemble C d'éléments de T compris dans cet intervalle en comptant le nombre d'éléments inférieurs et supérieurs à cet intervalle ;
- ▶ Il y a échec si le médian ne se trouve pas dans C ou si sa taille est trop grande ;
- ▶ On trie C et on retrouve le médian de T à partir du tri.

Calcul du médian : l'algorithme

R est un tableau de taille $\lceil n^{\frac{3}{4}} \rceil$.

C est un tableau de taille variable $\leq n$.

```
For  $i$  from 1 to  $\lceil n^{\frac{3}{4}} \rceil$  do  $R[i] \leftarrow T[\text{Sample}(1 \dots n, \text{uniform})]$ 
```

```
Sort( $R, \lceil n^{\frac{3}{4}} \rceil$ )
```

```
 $d \leftarrow R[\lfloor \frac{1}{2}n^{\frac{3}{4}} - \sqrt{n} \rfloor]$ ;  $f \leftarrow R[\lfloor \frac{1}{2}n^{\frac{3}{4}} + \sqrt{n} \rfloor]$ 
```

```
 $\ell_d \leftarrow 0$ ;  $\ell_f \leftarrow 0$ ;  $j \leftarrow 0$ 
```

```
For  $i$  from 1 to  $n$  do
```

```
  If  $T[i] < d$  then  $\ell_d \leftarrow \ell_d + 1$ 
```

```
  Else If  $T[i] > f$  then  $\ell_f \leftarrow \ell_f + 1$ 
```

```
  Else  $j \leftarrow j + 1$ ;  $C[j] \leftarrow T[i]$ 
```

```
If  $\ell_d > \frac{n}{2}$  or  $\ell_f > \frac{n}{2}$  or  $j > 4n^{\frac{3}{4}}$  then Return(Fail)
```

```
Sort( $C, j$ ); Return( $C[\lfloor \frac{n}{2} \rfloor - \ell_d]$ )
```

Observation. Cet algorithme peut être transformé en algorithme de Las Vegas.

Complexité et correction (probabiliste)

Complexité en $O(n)$.

L'initialisation de R se fait en $O(n^{\frac{3}{4}} \log(n))$, donc en $O(n)$.

Le tri de R se fait en $O(n^{\frac{3}{4}} \log(n^{\frac{3}{4}}))$, donc en $O(n)$.

La boucle principale se fait en $O(n)$.

Le tri (éventuel) de C se fait en $O(n^{\frac{3}{4}} \log(n^{\frac{3}{4}}))$, donc en $O(n)$.

Correction.

d et f sont des valeurs de T et $C[1, j]$ contient le sous-ensemble trié des valeurs comprises entre d et f .

Si $\ell_d \leq \frac{n}{2}$ alors $d \leq m$.

Si $\ell_f \leq \frac{n}{2}$ alors $f \geq m$.

Par conséquent m est une des valeurs $C[1, j]$ et plus précisément la $\lceil \frac{n}{2} \rceil - \ell_d$ ième valeur.

Probabilité d'échec (1)

La probabilité d'échec est majorée



par la somme des probabilités des événements suivants :

E_1 Il y a moins de $\frac{1}{2}n^{\frac{3}{4}} - \sqrt{n}$ valeurs (répétées) de R inférieures ou égales à m .

E_2 Il y a moins de $\frac{1}{2}n^{\frac{3}{4}} - \sqrt{n}$ valeurs (répétées) de R supérieures ou égales à m .

E_3 Il y a plus de $4n^{\frac{3}{4}}$ valeurs de T entre d et f .

- $m < d$ implique E_1 .



Probabilité d'échec (2)

Rappel Chernoff-Hoeffding. Soit $(X_i)_{i \leq k}$ une famille de variables aléatoires indépendantes avec X_i à valeurs dans $[a_i, b_i]$.

Soit $X = \sum_{i \leq k} X_i$ et $\mu = \mathbf{E}(X)$. Alors : $\Pr(X \leq \mu - \varepsilon) \leq e^{-\frac{2\varepsilon^2}{\sum_{i \leq k} (b_i - a_i)^2}}$

Application.

Si la i ème valeur de R est inférieure ou égale à m alors $X_i = 1$ sinon $X_i = 0$.

Ici $[a_i, b_i] = [0, 1]$, $k = n^{\frac{3}{4}}$, $\mu = \frac{\lceil n/2 \rceil}{n} n^{\frac{3}{4}} \geq \frac{1}{2} n^{\frac{3}{4}}$ et $\varepsilon = \sqrt{n}$.

D'où $\Pr(E_1) \leq e^{-\frac{2n}{n^{3/4}}} = e^{-2n^{1/4}}$ et $\Pr(E_2) \leq e^{-2n^{1/4}}$.

Probabilité d'échec (3)

Si E_3 est réalisé alors :

$E_{3,1}$ soit il y a au moins $2n^{3/4}$ éléments supérieurs à m dans C ;



$E_{3,2}$ soit il y a au moins $2n^{3/4}$ éléments inférieurs à m dans C .

$E_{3,1}$ implique qu'il y a au moins $2n^{3/4}$ éléments compris entre m et f dans T .

D'où f est supérieure ou égale à $\frac{n}{2} + 2n^{3/4}$ valeurs de T

et R contient au moins $\frac{1}{2}n^{3/4} - \sqrt{n}$ valeurs supérieures ou égales

à $\frac{n}{2} + 2n^{3/4}$ valeurs de T .



Probabilité d'échec (3)

Rappel Chernoff-Hoeffding. Soit $(X_i)_{i \leq k}$ une famille de variables aléatoires indépendantes avec X_i à valeurs dans $[a_i, b_i]$.

Soit $X = \sum_{i \leq k} X_i$ et $\mu = \mathbf{E}(X)$. Alors : $\Pr(X \geq \mu + \varepsilon) \leq e^{-\frac{2\varepsilon^2}{\sum_{i \leq n} (b_i - a_i)^2}}$

Application.

Si la i ème valeur de R est parmi les $\frac{n}{2} + 2n^{3/4}$ valeurs les plus grandes de T alors $X_i = 1$ sinon $X_i = 0$.

Ici $[a_i, b_i] = [0, 1]$, $k = n^{3/4}$, $\mu = \frac{1}{2}n^{3/4} - 2\sqrt{n}$ et $\varepsilon = \sqrt{n}$.

D'où $\Pr(E_{3,1}) \leq e^{-2n^{1/4}}$ et $\Pr(E_{3,2}) \leq e^{-2n^{1/4}}$.



Contraction aléatoire d'un multi-graphe

Soit un multi-graphe connexe $G = (V, E)$ avec $1 < n = |V|$ et $m = |E|$.

On considère un ordonnancement aléatoire de $E = (e_i)_{i \leq m}$, uniformément choisi.

Pour tout $i \leq m$, $G_i = (V, (e_j)_{j \leq i})$.

Illustration.



Recherche de coupe par contraction

On cherche un i tel que G_i ait deux composantes connexes (CC) notées V_0 et V_1 .



On calcule les CC de $G_{\lceil \frac{m}{2} \rceil} : \{W_k\}_{k \leq K}$.

- ▶ Si $K = 2$ c'est gagné ;
- ▶ Si $K > 2$ alors on itère le procédé sur $G' = (\{W_k\}_{k \leq K}, (e_j)_{\frac{m}{2} < j \leq m})$;
- ▶ Si $K = 1$ alors on itère le procédé sur $G_{\lceil \frac{m}{2} \rceil}$.

Une itération s'effectue en temps linéaire par rapport au nombre des arêtes.

D'où une complexité en $O(m) + O(\frac{m}{2}) + \dots = O(m)$.

Illustration.



Coupe minimale d'un multi-graphe

On cherche une partition $V = V_0 \uplus V_1$

telle que l'ensemble des arêtes joignant V_0 à V_1 soit de taille minimale.

Un algorithme de Monte Carlo pour la coupe minimale.

- ▶ On itère p fois le procédé précédent ;
- ▶ On renvoie la partition qui minimise la coupe.

Complexité de l'algorithme en $O(pm)$.

Quelle valeur choisir pour p ?

Observation.


Cet algorithme ne peut pas être transformé en un algorithme de Las Vegas.

Analyse de l'algorithme (1)

La probabilité qu'une coupe minimale soit trouvée par une itération de l'algorithme est supérieure ou égale à $\frac{2}{n(n-1)}$.

Preuve. Notons F les arêtes d'une coupe minimale $V = V_0 \uplus V_1$ et $k = |F|$.
Il suffit qu'à chaque diminution (jusqu'à deux) du nombre de CC les arêtes de F ne soient pas choisies.

Invariant de boucle. Soit $\{W_k\}_{k \leq K}$ les composantes connexes de G_i .
Alors il existe $\{1, \dots, K\} = I_0 \uplus I_1$ t.q. pour $m \in \{0, 1\}$, $V_m = \biguplus_{k \in I_m} W_k$.



Analyse de l'algorithme (2)

Preuve (suite). $m \geq \frac{kn}{2}$ car chaque sommet a au moins k arêtes.

Soit le multi-graphe des CC avant la $j + 1$ ème diminution de CC.

Puisque les arêtes de F n'ont pas été choisies, sa coupe minimale est "inchangée".

Il a $n - j$ sommets donc au moins $k(n - j)/2$ arêtes.

La probabilité de ne pas choisir une arête de F est minorée par

$$\frac{k(n - j)/2 - k}{k(n - j)/2} = \frac{n - 2 - j}{n - j}$$

La probabilité d'obtenir la coupe minimale est donc minorée par :

$$\prod_{j=0}^{n-3} \frac{n - 2 - j}{n - j} = \frac{2}{n(n - 1)}$$

□

D'où une probabilité d'erreur majorée par $(1 - \frac{2}{n(n-1)})^p \leq e^{-\frac{2p}{n(n-1)}}$.

Si $p = \frac{n(n-1) \log(n)}{2}$ alors la complexité de l'algorithme est $O(mn^2 \log(n))$

avec probabilité d'erreur inférieure ou égale à $\frac{1}{n}$.

Développements possibles

- Tri rapide probabiliste : présentation et analyse de complexité
- Structure à trous : présentation et analyse (partielle) de complexité
- Dérandomisation de l'algorithme probabiliste de recherche de coupe maximale
- Algorithme probabiliste de recherche de coupe minimale