

## Analyse d'algorithme : Complexité. Exemples

Introduction : on veut pouvoir résoudre un problème

P, quelle que soit les conditions de départ, en suivant un schéma de résolution préétabli et reproduitible par n'importe qui.

Def 1: Un algorithme devait un traitement pour un certain nombre, fini, de données.

- Un algorithme est la composition d'un nombre fini d'étape, chaque étape étant faite d'un nombre fini d'opérations dont chacune est :
  - définie de façon rigoureuse et non ambiguë.
  - effectuée (peut-être réalisée par une machine).

Objectifs: Que ce soit la donnée sur laquelle on travaille un algorithme doit l'apporter au terminus après un nombre fini d'opérations

Def 2: Soit A un algorithme. On choisit un ensemble d'opération fondamentales permis les opérations peuvent être effectuées par l'algo. Pour une instance x du problème P, on définit C(x) comme le nombre d'opérations élémentaires effectuées par l'algo A sur l'entrée x.

Ex: Recherche séquentielle d'un nom dans un annuaire contenant n noms.

Opération fondamentale : comparaison.

→ si le nom recherché est au position i, alors

$$C(x) = i.$$

Pour s'exécuter, l'algorithme A doit manipuler les données du problème, ainsi que des données auxiliaires. On suppose que l'on stock la informations dans des blocs mémoire.

Def 3: Soit x une instance, on note  $C_M(x)$  le nombre de blocs mémoires utilisés par l'algorithme A de l'environnement x.

Esi Recherche séquentielle d'un élément dans un tableau de taille n : il faut n+1 blocs mémoires

### II - Complexité en temps

Def 4: Soit  $D_n$  l'ensemble des données de taille n traitées par l'algorithme A, on définit les complexités

$$\text{Au pire: } C_{\max}(n) = \max_{x \in D_n} C(x)$$

$$C_{\min}(n) = \min_{x \in D_n} C(x)$$

$$C_{moy}(n) = \frac{1}{|D_n|} \sum_{x \in D_n} C(x)$$

où  $|D_n|$  est une distribution de proba sur  $D_n$ .

En pratique on ne s'intéresse pas à l'expression exacte de son complexité. On veut simplement une majoration asymptotique.

Def: Soient  $f, g$  deux fonctions de  $\mathbb{N}$  dans  $\mathbb{N}$ , on dit que :

- $f = \Theta(g)$  si  $f = O(g)$  et  $g = O(f)$ .
- $f = \Theta(g)$  si  $f = O(g)$  et  $g = O(f)$ .

Exemple DVPT Comparaison du Triapide et du Tri-fusion.

## 2) Techniques de calculs.

• Lois de l'utilisation d'algorithme récursifs, on extrait souvent une récurrence des algorithmes sur les séquences ou les séries.

Exemple: Recherche dichotomique dans un tableau trié.

On a deux outils

Th (Général) Soient  $a > 1$  et  $b > 1$  deux réels,  $f(n)$  une fonction et

$T(n)$  défini pour les entiers positifs par la récurrence

$$T(n) = a T\left(\frac{n}{b}\right) + f(n)$$

alors  $T(n)$  est asymptotiquement borné de la façon suivante :

1) si  $f(n) = O(n^{\log_b(a)-1})$  pour un certain  $\varepsilon > 0$  alors  $T(n) = \Theta(n^{\log_b(a)})$

2) si  $f(n) = \Theta(n^{\log_b(a)})$  alors  $T(n) = \Theta(n^{\log_b(a) \log_b(n)})$

3) si  $f(n) = \Omega(n^{\log_b(a)})$  pour un certain  $\varepsilon > 0$  et si

-  $\frac{f(n)}{n} \leq C$  pour un certain  $C < 1$  et pour n suffisamment grand, alors  $T(n) = \Theta(f(n))$ .

Utile pour le séquençage: Lorsque il y a tomber une séquence de séquences du type

$$C(a) = C(a-2) + C(a-1)$$

on multiplie par  $z^a$  des deux côtés, et on somme pour toutes les valeurs de  $a$ .

$$\sum_{n \in \mathbb{N}} C(n) z^n = z^2 \sum_{n \in \mathbb{N}} C(n-2) z^{n-2} + z^1 \sum_{n \in \mathbb{N}} C(n-1) z^{n-1}$$

Puis on résoud l'équation  $f(z) = z^2 f(z) + z^1 f(z)$

C'est donc le  $n$ -ième coefficient de la série de Taylor de  $f$ .

• Analyse Amortie : on prend de majorer chaque opération individuellement on s'intéresse au coût moyen de chaque opération dans une suite de  $n$  opérations.

Méthode de l'aggrégat: Si une suite de  $n$  opérations coûte  $T(n)$ , alors le coût amorti de chaque opération est  $\frac{T(n)}{n}$ .

Ex: Imprimation d'un caractère binaire de  $k$  bits.

Entrez : Tableau A.

tant que  $i < A$ .longueur et  $A[i] = 4$   
 $A[i] = 0$

$i = i+1$   
 si  $i < A$ .longueur  
 $A[i] = 1$

Sous une suite de  $n$  opérations, en fait, le  $i$ -ième bit n'est modifié que pour  $\lfloor \frac{i}{2} \rfloor$  fois, ce qui donne :  $T(n) = \sum_{i=0}^{n-1} \lfloor \frac{i}{2} \rfloor < n \sum_{i=0}^{n-1} \frac{1}{2} < 2n$

Pour le coût amortie est  $\frac{T(n)}{n} = O(1)$  (théorème  $O(k)$ ).

- Méthode comptable: si certaines opérations ne peuvent pas être effectuées avant d'autres opérations, alors on va isoler les premières et on sauvegarde les données :

Ex: pile: empiler 1       $\rightarrow$       un pile 2  
dépiler 1                   $\rightarrow$       dépiler 0  
vide                         $\rightarrow$       vide 0

- Méthode du potentiel: Dans cette méthode, on offre un potentiel de travail à la structure de donnée. Le coût de chaque opération est donc le coût réel + différence de potentiel.

Ex: Potentiel = longueur de la pile;  $D_i$  = abitudes de donnee après l'opérat

$$\text{Empiler } = 1 + (\phi(D_n) - \phi(D_{n-1})) = 1+1 = 2$$

$$\text{vidé} = k + (\phi(D_n) - \phi(D_{n-1})) = k+0-k=0$$

### 3) Composée memoisé

Deux cas algorithmique qui doit être précédé de nombreuses fois sur un exemple d'arbre, il est plus réaliste de calculer la complexité moyenne.

#### Dans type de problèmes:

- Quelle destination de proba utiliser?

Ex: algorithme de traduction mot à mot. Pour traduire du français vers une autre langue, on aimeraient que la probabilité d'apparition de "f" soit plus élevée que celle de "mordue". (sauf si c'est un livre de cassure...).

- Étant donné une distribution de proba, construire un algorithme qui minimise la complexité moyenne.

### Ex:DPT : construction des ABRO

(Et je crois qu'on peut parler de table de Hachage?)

### III. Le bon compromis espace/temps.

L'étude de la complexité en espace est plus facile de la machine que celle de la complexité en temps. La principale réduction est que l'accès en mémoire secondaire est beaucoup plus lent que l'accès à la mémoire primaire. Une grosse complexité en espace, peut ralentir un algorithme en pratique.

Mais on peut aussi diminuer la complexité en temps en augmentant la complexité en espace. Cette astuce est utilisée au programme - ~~matrice~~ matrice dynamique.

Ex: Fibonacci récursif:  $C(n) = O(4^n)$

Fibonacci programmation dynamique:  $C(n) = O(n)$ .

### Construction d'ABRO ✓ (encore!).

Je veux ... : @

Bibliog: Frédéricoux (Définitions) et (ABRO)

Caract

(Analyse amortie)

Flajolet

(Serie Générales)

return  $O_i$

# Tri Rapide - Tri Fusion

[Comment]

## FUSION ( $A, p, q, r$ )

$$n_1 \leftarrow q-p+1$$

$$n_2 \leftarrow r-q$$

Créer Tableau  $L[i, n_1+1]$

Créer Tableau  $D[i, n_2+1]$

Pour  $i$  de  $1$  à  $n_1$   $L[i] \leftarrow A[p+i-1]$

Pour  $j$  de  $1$  à  $n_2$   $D[j] \leftarrow A[q+j-1]$

$L[n_1+1] \leftarrow \infty$ ;  $D[n_2+1] \leftarrow \infty$

$$i := 1 \quad j := 1.$$

Pour  $R$  de  $p$  à  $r$  faire

Si  $L[i] \leq R[j]$

Alors  $A[R] \leftarrow L[i]$

$$i \leftarrow i+1$$

Sinon  $A[R] \leftarrow R[j]$

$$j \leftarrow j+1$$

## Algorithmes

## PARTITION ( $T, p, r$ )

$$x \leftarrow A[r]; i \leftarrow p-1$$

Pour  $j$  de  $p$  à  $r-1$  faire

Si  $A[i:j] \leq x$  Alors

$$l \leftarrow i+1$$

$$A[i:j] \leftrightarrow A[l:j]$$

$$A[i+1] \leftrightarrow A[r]$$

Retourner  $i+1$ .

## TRI-FUSION ( $T, p, r$ )

Si  $p < r$  Alors

$$q \leftarrow \lfloor \frac{p+r}{2} \rfloor$$

(\* Coût de séparation nul \*)

TRI-FUSION ( $T, p, q$ )

TRI-FUSION ( $T, q+1, r$ )

FUSION ( $T, p, q, r$ )

## TRI-RAPIDE ( $T, p, r$ )

Si  $p < r$  Alors

$$q \leftarrow \text{PARTITION}(T, p, r)$$

TRI-RAPIDE ( $T, p, q-1$ )

TRI-RAPIDE ( $T, q+1, r$ )

(\* Coût de Fusion nul \*)

Complexité en temps Ici, on ne compte que le nombre de comparaisons.

Pour le TRI-FUSION : Puisque FUSION fait exactement  $n$  comparaisons sur un tableau de taille  $n$ .

$$\text{On a } T(n) = T\left(\lfloor \frac{n}{2} \rfloor\right) + T\left(\lceil \frac{n}{2} \rceil\right) + n \quad T(0) = T(1) = 1.$$

On résout la récurrence pour  $n = 2^{k+1}$ ,

$$T(2^{k+1}) = 2T(2^k) + 2^{k+1}$$

$$\text{Soit } \frac{T(2^{k+1})}{2^{k+1}} = \frac{T(2^k)}{2^k} + 1$$

$$\text{Par récurrence: } \frac{T(2^k)}{2^k} = k$$

Donc, en supposant que la complexité est une fonction croissante de  $n$ :

$$\boxed{T_F(n) = \Theta(n \log n)}.$$

Pour le TRI-RAPIDE : PARTITION effectue  $n-1$  comparaisons sur un tableau de taille  $n$ . Par contre, le coût de TRI-RAPIDE dépend de l'entrée.

Au PIRE : l'un des deux tableaux obtenus est vide, à chaque appel récursif :

$$C_p(n+1) = n + C_p(n) \quad \text{soit} \quad C_p(n) = \Theta(n^2)$$

En MOYENNE : si le pivot est en  $j$ -ième position après PARTITION.

L'algorithme s'appelle récursivement sur des entrées de taille  $j-1$  et  $n-j$ .

On suppose que toutes les permutations de l'entrée sont équiprobables.

La probabilité que le pivot soit en  $j$ -ième position est donc de  $\frac{1}{n}$ , soit

$$\begin{aligned} C_{\text{moy}}(n) &= n-1 + \frac{1}{n} \sum_{j=1}^n (C_{\text{moy}}(j-1) + C_{\text{moy}}(n-j)) , \quad C(0) = C(1) = 0 \\ &= n-1 + \frac{2}{n} \sum_{j=1}^{n-1} C(j). \end{aligned}$$

$$\text{Soit } n(C(n) - n+1) = 2 \sum_{j=1}^{n-1} C(j)$$

$$\text{Et, au rang } n-2 : (n-1)(C(n-1) - n+2) = 2 \sum_{j=1}^{n-2} C(j).$$

$$\text{On soustrait : } nC(n) - (n-1)C(n-1) - 2n+2 = 2C(n-1)$$

$$\text{Soit } \frac{C(n)}{n+1} = \frac{C(n-1)}{n} + \frac{2(n-1)}{n(n+1)} \leq \frac{C(n-1)}{n} + \frac{2}{n+1}$$

$$\text{Par récurrence : } C(n) \leq (n+1) \sum_{k=1}^n \frac{2}{k+1} = 2(n+1) \left( H_{n+1} - 1 \right) \underset{n \rightarrow \infty}{\sim} 2n \ln n$$

$$\text{Donc } \boxed{C(n) = \Theta(n \ln n)}$$
 mais la constante est de l'ordre de 1,38.

Contre 3 pour le TRI-FUSION. Celui-ci a donc l'air plus efficace...

Mais on n'a pas pris en compte le coût des affectations dans les tableaux :

$2n+2$  pour FUSION contre  $2 \cdot \binom{n-1}{2} + 2 = n+1$  en moyenne pour PARTITION.

Cela ne modifie pas la complexité asymptotique, mais relativise l'importance de nos constantes...

Enfin, il faut prendre en compte la complexité en espace, mais il est difficile de la calculer précisément...

En pratique, c'est le TRI-RAPIDE qui donne les meilleures performances.

# Arbre Binaire de Recherche Optimal L Cormen

On veut construire une structure de donnée gérant un dictionnaire et l'ensemble des clés est statique. Le but est de minimiser le coût moyen d'une recherche (la seule opération du dictionnaire).

Soit  $R_1 \dots R_n$  les clés du dictionnaire. L'univers des clés possibles n'étant pas limité à  $\{R_1, R_2\}$ , on introduit des clés factices  $d_0 \dots d_n$  qui signifient "l'entrée se trouve entre  $R_i$  et  $R_{i+1}$ ".

On connaît les probabilités que la recherche renvoie  $R_i$  (tableau  $p[1..n]$ ) ou  $d_j$  (tableau  $q[0..n]$ ): on a  $\sum_{i=1}^n p_i + \sum_{j=0}^n q_j = 1$ .

On va utiliser un ABR, qui donne un coût au pire de  $\Theta(\log n)$  pour l'opération RECHERCHER. La complexité moyenne d'une recherche est alors:

$$C_p = \sum_{i=1}^n (\text{prof}_T(R_i) + 1) p_i + \sum_{j=0}^n (\text{prof}_T(d_j) + 1) q_j$$


Trouver  $T$  tel  $C_p$  minimal?

- Les clés factices sont des feuilles (fin de recherche). Le nombre d'ABR que l'on peut construire est donc le nombre d'arbres binaires à  $n$  noeuds, qui est exponentiel.
- L'algorithme naïf d'énumération est donc inefficace, on va faire appel à la Programmation Dynamique

## 1) Sous-Problèmes

Un sous-arbre d'un ABR contient les clés  $R_i \dots R_j$  et  $d_{i+1} \dots d_j$   $\left\{ \begin{array}{l} i, j \in \{1, \dots, n\} \\ i \leq j+1 \end{array} \right.$

Dans un ABRO, tout sous-arbre doit être optimal. Si la racine est  $R_n$ , alors il est de la forme  $T' = (R_n)$



$$\text{On note } e[i, j] = \sum_{k=i}^j (\text{prof}_{T'}(R_k) + 1) p_k + \sum_{l=i+1}^j (\text{prof}_{T'}(d_l) + 1) q_l.$$

$$\text{et } w[i, j] = \sum_{k=i}^j p_k + \sum_{l=i+1}^j q_l \quad \text{la probabilité que la recherche s'arrête dans } T'.$$

## 2) Formule de récurrence

$$\text{On a: } w[i, j] = w[i, j-1] + p_j + q_j$$

$$\text{et } e[i, j] = w[i, j] + \sum_{\text{Gauche}(T')} \text{prof}_{T'}(R_k) p_k + \sum_{\text{Gauche}(T')} \text{prof}_{T'}(d_l) q_l + \sum_{\text{Droit}(T')} \text{prof}_{T'}(R_k) p_k + \sum_{\text{Droit}(T')} \text{prof}_{T'}(d_l) q_l$$

$$\text{Donc } e[i, j] = w[i, j] + e[i, j-1] + e[j+1, j], \text{ où } R_n \text{ est la racine de } T'$$

### 3) Algorithm

ABRO ( $p[1..n]$ ,  $q[0..n]$ )

Créer-Tableau  $e[1..n+1, 0..n]$

Créer-Tableau  $w[1..n+1, 0..n]$

Créer-Tableau  $r[1..n, 1..n]$

Pour  $i$  de 1 à  $n+1$  faire ( $r[i,j]$  est la racine du sous-ABRO  $\langle p_{i..n}, q_{i..n} \rangle$ )

    |  $e[i, i-1] := q_{i-1}$

    |  $w[i, i-1] := q_{i-1}$

Pour  $l$  de 1 à  $n$  faire

    | Pour  $i$  de 1 à  $n+1-l$  faire

        |  $j := i + l - 1$

        |  $e[i, j] := \infty$

        |  $w[i, j] := w[i, j-1] + p[j] + q[j]$

        | Pour  $\tau$  de  $i$  à  $j$  faire

            |  $t := e[i, \tau-1] + e[\tau+1, j] + w[i, \tau]$

            | Si  $t < e[i, j]$  alors

                |  $e[i, j] := t$

                |  $r[i, j] := \tau$

    | Retourner  $e$  et  $r$

### Correction

• Terminaison = boucles Pour

• Invariant de boucle:

" $e[i, j]$  est le coût moyen optimal

d'une recherche dans un ABR

de clés  $p_i \dots p_j$  et  $d_{i-1} \dots d_j$  de


probabilités  $\frac{1}{w[i, j]} p[i..j]$  et  $\frac{1}{w[i, j]} q[i..j]$ ".

$$\Rightarrow C_T = e[1..n]$$

### 4) Complexité

• Temporelle au pire et en moyenne : dans les deux cas la boucle sur  $\tau$  est en  $\Theta(1)$ .  
Donc  $C(n) = \Theta(n^3)$

• Spatiale : on construit les tableaux :



$$= \Theta(n^2).$$

• Optimisation Spatiale :

Pour  $w$ , on peut se contenter d'un tableau  $[1..n+1]$

Pour les deux autres tableaux, on doit conserver toute l'information.

5) Exemple : Cf [Cormen], p 348 et 353.

## Algorithme de Dijkstra : Complexité [Cormen]

Donnée:  $G = (S, A)$  graphe,  $W: A \rightarrow \mathbb{N}$  fonction de poids,  $s \in S$  source.

But: Calculer  $d(s, v)$  pour  $v \in S$  et donner un chemin de  $s$  à  $v$  de longueur minimale.

On note  $S = [1..n]$ , on va construire  $d[1..n]$  et  $\pi[1..n]$  à l'aide d'une file de priorité min  $F$  d'ensemble  $[1..n]$  dont les clés sont stockées dans  $d[1..n]$ .

On utilise les opérations  $\text{INSERER}(F, v, \text{clé}) \rightsquigarrow d[v] \leftarrow \text{clé}, v \text{ dans } F$   
 $\text{EXTRAIRE\_MIN}(F) \rightsquigarrow$  Renvoie  $v \in F$  tq  $d[v]$  minimal dans  $F$ ,  
 $\text{DIMINUER\_CLE}(F, v, \text{clé}) \rightsquigarrow$  Si  $v \in F$ ,  $d[v] \leftarrow \text{clé}$ , réorganiser  $F$

et la fonction :

$\text{RELACHER}(u, v, W)$ :	$\begin{cases} \text{Si } d[v] > d[u] + W(u, v) \text{ Alors} \\ \quad \text{DIMINUER\_CLE}(F, v, d[u] + W(u, v)) \\ \quad \pi[v] \leftarrow u. \end{cases}$
------------------------------	--

Dans  $\text{DIJKSTRA}(G, W, s)$

$\begin{cases} \text{Créer - Tableau } \pi[1..n] \text{ à NIL} \\ \text{Créer - Tableau } d[1..n] \\ F := \emptyset, \text{ Pour } v \in S \text{ Faire } \text{INSERER}(F, v, \infty) \\ \text{DIMINUER\_CLE}(F, s, 0) \\ \text{Tant Que } F \neq \emptyset \text{ Faire} \\ \quad u \leftarrow \text{EXTRAIRE\_MIN}(F) \\ \quad \text{Pour } v \in \text{Adj}[u] \text{ Faire} \\ \quad \quad \text{RELACHER}(u, v, W). \end{cases}$
--

Terminaison: Le "variant" de la boucle Tant que est  $|F|$

Correction: Demander à Rémi (Lesson 901)

Complexité (en temps au pire).

On note  $I(n)$ ,  $E(n)$  et  $D(n)$  les complexités de  $\text{INSERER}$ ,  $\text{EXTRAIRE\_MIN}$ ,  $\text{DIMINUER\_CLE}$ .  
Alors  $C(n) = 2n+1 + \sum_{k=0}^{n-1} I(k) + \sum_{k=1}^n (E(k) + |\text{Adj}|(k)D(k))$   
 $\leq n \cdot I(n) + nE(n) + 2A(2+D(n)) + O(n)$

Implémentation $F$	$I(n)$	$E(n)$	$D(n)$	Matrice d'adjacence	Liste d'adjacence
Tableau	1	$n$	1	$n+n^2+n^3+O(n) = \Theta(n^3)$	$\Theta(n^2+A) = \Theta(n^2)$
Tas Min (Amorti)	$O(1)$	$\log n$	$\log n$	$O(n)+n \log n + n^2(2+\log n) = \Theta(n^2, \log n)$	$\Theta((n+A)\log n)$

Conclusion : Dans les deux cas, on préférera une liste d'adjacence pour implémenter notre graphe, mais le gain n'est pas substantiel.. Si le graphe est peu dense (par exemple, si on sait borner le degré des sommets du graphe), l'implémentation de F par `traj_min` est beaucoup plus efficace, mais elle est moins efficace pour un graphe très dense!