

IFT2015 hiver 2010 — Notes de cours

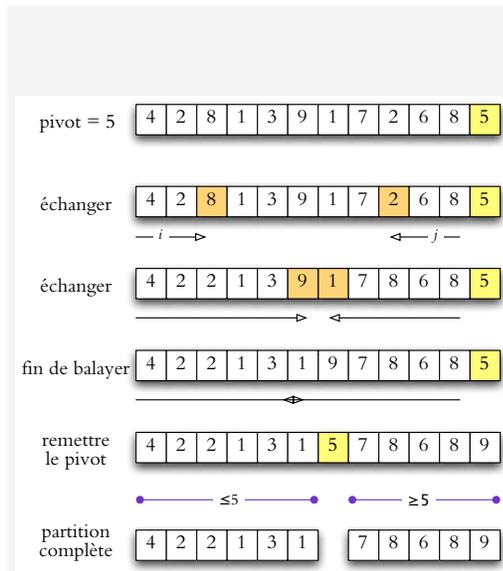
Miklós Csűrös

24 février 2010

10 Tri rapide

10.1 Algorithme

La récursion du **tri rapide** (*quicksort*) représente une logique complémentaire à celle du tri par fusion. De même façon, le tableau à l'entrée est divisé en deux et les deux moitiés sont triés par des appels récursifs. En tri par fusion, la division ne dépend pas du contenu du tableau — les deux moitiés sont combinés après les appels récursifs. En tri rapide, la division se fait en groupant les éléments dans les deux moitiés à l'aide d'un élément appelé le **pivot** x . On place les éléments inférieurs à x à la gauche, et ceux supérieurs à x à la droite du tableau. Avec x au milieu, on devra pas combiner les deux sous-tableaux après les avoir triés. Donc on fait la majeure partie du travail avant les appels récursifs, en une structure algorithmique de genre «combiner pour régner».



L'idée principale est la **partition** autour d'un pivot.

```
Algo QUICKSORT( $A[0..n-1]$ ,  $g$ ,  $d$ ) // tri de  $A[g..d]$ 
```

```
Q1 si  $g \geq d$  alors retourner // cas de base
```

```
Q2  $i \leftarrow$  PARTITION( $A$ ,  $g$ ,  $d$ )
```

```
Q3 QUICKSORT( $A$ ,  $g$ ,  $i-1$ )
```

```
Q4 QUICKSORT( $A$ ,  $i+1$ ,  $d$ )
```

```
Algo PARTITION( $A$ ,  $g$ ,  $d$ )
```

```
P1 choisir le pivot  $p \leftarrow A[d]$ 
```

```
P2  $i \leftarrow g-1$ ;  $j \leftarrow d$ 
```

```
P3 boucler
```

```
P4 faire  $i \leftarrow i+1$  tandis que  $A[i] < p$ 
```

```
P5 faire  $j \leftarrow j-1$  tandis que  $j \geq l$  et  $A[j] > p$ 
```

```
P6 si  $i \geq j$  alors sortir de la boucle
```

```
P7 échanger  $A[i] \leftrightarrow A[j]$ 
```

```
P8 échanger  $A[i] \leftrightarrow A[d]$ 
```

```
P9 retourner  $i$ 
```

Pour trier un tableau $A[0..n-1]$ en ordre croissant, on exécute $\text{QUICKSORT}(A, 0, n-1)$. C'est un tri en place.

10.2 Performances

La partition (Lignes P3–P7) se fait en un temps $\Theta(n)$. Le temps de calcul est donc

$$T(n) = \Theta(n) + T(i) + T(n-1-i).$$

La récurrence dépend de l'indice i du pivot.

| | pivot i | récurrence $T(n)$ | solution $T(n)$ |
|---------------------|------------------|--|------------------------|
| Meilleur cas | $(n - 1)/2$ | $2 \cdot T((n - 1)/2) + \Theta(n)$ | $\Theta(n \log n)$ |
| Pire cas | $0, n - 1$ | $T(n - 1) + \Theta(n)$ | $\Theta(n^2)$ |
| Moyen cas | aléatoire | $\mathbb{E}T(n) = 2\mathbb{E}T(i) + \Theta(n)$ | $\Theta(n \log n)$ |

Le pire cas arrive (entre autres) quand on a un tableau trié au début !

Exercice 10.1. On a aussi un temps de calcul quand la partition sépare au moins, disons un tiers des éléments. En général, supposons qu'il existe un $m \geq 2$ et un N tels que $\min\{i, n - 1 - i\} \geq n/m$ pour la partition de tous les sous-tableaux avec une longueur $n \geq N$. On a donc $T(n) \leq \Theta(n) + T((n - 1)/m) + T((n - 1)(m - 1)/m)$ pour $n \geq N$. Démontrez que $T(n) = O(n \log n)$.

10.3 Améliorations

Petits sous-tableaux. Il vaut mieux d'utiliser un tri par insertion quand $d - g$ est petit ($\leq 5 \cdot 20$). En fait, on peut ignorer les petits sous-tableaux entièrement (tester $d < g + 10$ en Ligne Q1). Il faut juste faire un tri par insertion une fois à la fin.

Choix du pivot. Deux choix performant très bien en pratique : médiane ou aléatoire.

Médiane de trois

| | |
|------|---|
| P1.1 | si $d \geq g + 2$ alors |
| P1.2 | si $A[g] > A[d - 1]$ alors échanger $A[g] \leftrightarrow A[d - 1]$ |
| P1.3 | si $A[d] > A[d - 1]$ alors échanger $A[d] \leftrightarrow A[d - 1]$ |
| P1.4 | si $A[g] > A[d]$ alors échanger $A[g] \leftrightarrow A[d]$ |
| P1.5 | $p \leftarrow A[d]$ // $A[g] \leq A[d] \leq A[d - 1]$ |

Aléatoire

| | |
|------|------------------------------------|
| P1.1 | $k \leftarrow \text{RANDOM}(g, d)$ |
| P1.2 | $p \leftarrow A[k]$ |
| P1.3 | si $k \neq d$ alors |
| P1.4 | $A[k] \leftrightarrow A[d]$ |
| P1.5 | $A[d] \leftarrow p$ |

et on se sert des **sentinelles** $A[g], A[d - 1]$:

| | |
|-----|--|
| P2' | $i \leftarrow g; j \leftarrow d - 1$ |
| P5' | faire $j \leftarrow j - 1$ tandis que $A[j] > p$ |

10.4 Moyen cas

Théorème 10.1. Soit $D(n)$ le nombre moyen de comparaisons avec un pivot aléatoire, où n est le nombre d'éléments dans un tableau $A[0..n - 1]$. Alors,

$$\frac{D(n)}{n} = O(\log n).$$

Lemme 10.2. On a $D(0) = D(1) = 0$, et

$$D(n) = n - 1 + \frac{1}{n} \sum_{i=0}^{n-1} (D(i) + D(n - 1 - i)) = n - 1 + \frac{2}{n} \sum_{i=0}^{n-1} D(i).$$

Démonstration. Supposons que le pivot est le i -ème plus grand élément de A . Le pivot est comparé à $(n - 1)$ autre éléments pour la partition. Les deux partitions sont de tailles i et $(n - 1 - i)$. Or, i prend les valeurs $0, 1, \dots, n - 1$ avec la même probabilité. ■

Preuve de Théorème 10.1. Par Lemme 10.2,

$$\begin{aligned} nD(n) - (n-1)D(n-1) &= \left(n(n-1) + 2 \sum_{i=0}^{n-1} D(i) \right) - \left((n-1)(n-2) + 2 \sum_{i=0}^{n-2} D(i) \right) \\ &= 2(n-1) + 2D(n-1). \end{aligned}$$

D'où on a

$$\frac{D(n)}{n+1} = \frac{D(n-1)}{n} + \frac{2n-2}{n(n+1)} = \frac{D(n-1)}{n} + \frac{4}{n+1} - \frac{2}{n}.$$

Avec $E(n) = \frac{D(n)-2}{n+1}$, on peut écrire

$$E(n) = E(n-1) + \frac{2}{n+1}.$$

Donc,

$$\begin{aligned} E(n) &= E(0) + \frac{2}{2} + \frac{2}{3} + \cdots + \frac{2}{n+1} \\ &= \frac{D(0)-2}{1} + 2(H_{n+1} - 1) = 2H_{n+1} - 4 \end{aligned}$$

où $H_n = \sum_{i=1}^n 1/i$ est le n -ième nombre harmonique.

En retournant à $D(n) = 2 + (n+1)E(n)$, on a alors

$$D(n) = 2(n+1)H_{n+1} - 4n - 2 < 2nH_{n+1}$$

Donc le nombre de comparaisons en moyenne est tel que

$$\frac{D(n)}{n} < 2H_{n+1} = O(\log n).$$

■

En fait la preuve montre que $D(n)/n = (2 + o(1))H_n \sim 2 \ln n \approx 1.39 \lg n$. C'est seulement 39% pire que le meilleur cas !

10.5 Sélection

Supposons qu'on veut trouver le k -ème plus petit élément dans un tableau $A[0..n - 1]$. Il existe des algorithmes qui le font en temps $\Theta(n)$ au pire cas. En pratique, on peut se servir de la partition aussi pour arriver à $\Theta(n)$ en moyen cas. Idée de clé : après avoir appelé $i \leftarrow \text{PARTITION}(A, 0, n - 1)$, on trouve le k -ème élément en $A[0..i - 1]$ si $k < i$ ou en $A[i + 1..n - 1]$ si $k > i$. En même temps, on réorganise le tableau pour que $A[k]$ soit le k -ème plus petit élément.

```
Algo SELECTION( $A[0..n - 1], g, d, k$ )
S1 si  $d \leq g + 1$  alors // cas de base : 1 ou 2 éléments
S2   si  $d = g + 1$  et  $A[d] < A[g]$  alors échanger  $A[g] \leftrightarrow A[d]$  // 2 éléments
S3   retourner  $A[k]$ 
S4    $i \leftarrow \text{PARTITION}(A, g, d)$ 
S5   si  $k = i$  alors retourner  $A[k]$  // on l'a trouvé
S6   si  $k < i$  alors retourner SELECTION( $A, g, i - 1, k$ ) // continuer à la gauche
S7   si  $k > i$  alors retourner SELECTION( $A, i + 1, d, k$ ) // continuer à la droite
```

Comme c'est une **réursion terminale**, on peut transformer le code en forme itérative très facilement.

Théorème 10.3. Avec un pivot aléatoire, l'algorithme SELECTION fait $(2 + o(1))n$ comparaisons en moyenne.

Exercice 10.2. Démontrer Théorème 10.3.