

12 Tri rapide

12.1 Tri binaire

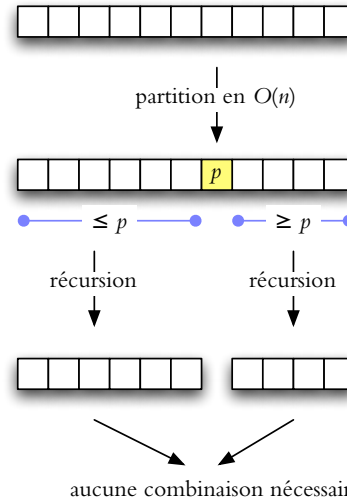
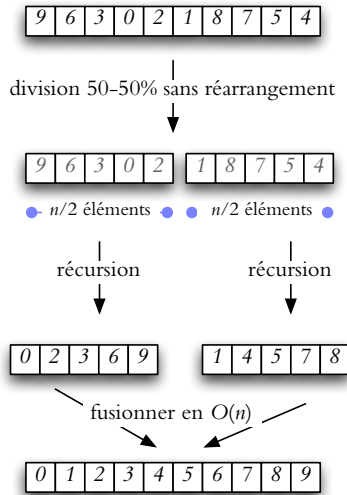
Supposons qu'il y a juste deux clés possibles (0 et 1) dans un tableau à trier. Alors on peut performer le tri en un temps linéaire à l'aide de deux indices qui balayent à partir des extrémités vers le milieu.

```

TRI01(A[0..n-1]) // tri binaire
B1 i ← 0; j ← n - 1
B2 loop
B3   while A[i] = 0 et i < j do i ← i + 1
B4   while A[j] = 1 et i < j do j ← j - 1
B5   if i < j then échanger A[i] ↔ A[j]
B6   else return
                    
```

Exercice 12.1. On peut rendre l'exécution plus efficace si on a des sentinelles aux deux extrémités : $A[0] = 0$ et/ou $A[n - 1] = 1$. Montrez une version améliorée de TRI01 qui place des sentinelles dans un premier parcours, et utilise des conditions plus simples dans les boucles intérieures.

12.2 Tri rapide

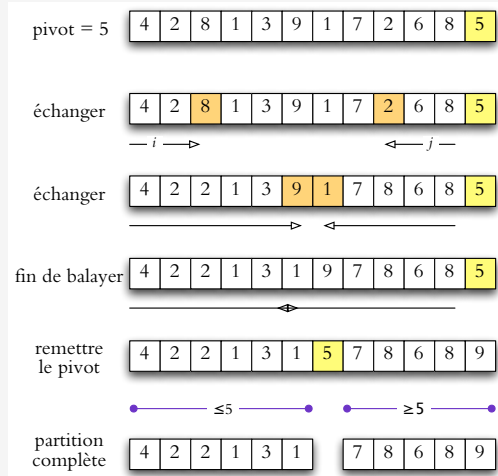


W_(fr)

Le **tri par fusion** utilise la logique de «diviser pour régner» : le tableau est divisé en deux sous-tableaux (en temps $O(1)$) qui sont triés ensuite dans des appels récursifs, et on combine les résultats (fusion) en un temps linéaire.

En **tri rapide**, on choisit un **pivot** p , et à l'aide des échanges d'éléments, on place les éléments inférieurs à p à la gauche, et ceux supérieurs à p à la droite du tableau. Après une telle partition, on peut procéder avec des appels récursifs aux deux sous-tableaux gauche et droit. Notez que le pivot n'est pas nécessairement la médiane : les sous-tableaux gaches et droits résultants peuvent avoir des tailles très différentes. La partition même suit la logique du tri binaire.

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



```

Algo QUICKSORT( $A[0..n-1], g, d$ ) // tri de  $A[g..d]$ 
Q1 if  $g \geq d$  then return // cas de base
Q2  $i \leftarrow$  PARTITION( $A, g, d$ )
Q3 QUICKSORT( $A, g, i-1$ )
Q4 QUICKSORT( $A, i+1, d$ )

Algo PARTITION( $A, g, d$ ) // partition de  $A[g..d]$ 
P1 choisir le pivot  $p \leftarrow A[d]$ 
P2  $i \leftarrow g-1; j \leftarrow d$ 
P3 loop
P4 do  $i \leftarrow i+1$  while  $A[i] < p$ 
P5 do  $j \leftarrow j-1$  while  $j \geq i$  et  $A[j] > p$ 
P6 if  $i \geq j$  then sortir de la boucle
P7 échanger  $A[i] \leftrightarrow A[j]$ 
P8 échanger  $A[i] \leftrightarrow A[d]$ 
P9 return  $i$ 
    
```

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.

12.3 Performances

Soit $m = d - g + 1$, le nombre des éléments dans le sous-tableau à trier, avec $m > 1$. La partition (Lignes P3–P7) se fait en un temps $\Theta(m)$. Le temps de calcul est donc

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

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 12.2. On a aussi $O(n \log n)$ quand la partition regroupe au moins une fraction fixée (p.e., $\alpha = 10\%$) des éléments à la fois. Démontrez que le tri rapide prend $O(n \log n)$ si la position i du pivot satisfait $\min\{i, m-1-i\} \geq m/3$ lors de la partition de sous-tableaux de taille m .

12.4 Améliorations

Petits sous-tableaux. Le **tri par insertion** est plus rapide que quicksort quand $d - g$ est petit ($g \geq d - \ell^*$ avec $\ell^* = 5..20$). En Ligne Q1, c'est mieux donc de faire le tri par insertion pour tels petits tableaux. En fait, on peut juste **ignorer** les petits sous-tableaux entièrement (retourner si $g \geq d - \ell^*$ en Ligne Q1). À la fin, il faut parcourir le tableau entier selon tri par insertion en $\Theta(n\ell^*) = \Theta(n)$.

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   if  $A[g] > A[d - 1]$  then échanger  $A[g] \leftrightarrow A[d - 1]$ 
P1.3   if  $A[d] > A[d - 1]$  then échanger  $A[d] \leftrightarrow A[d - 1]$ 
P1.4   if  $A[g] > A[d]$  then 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 if  $k \neq d$  then
P1.4    $A[k] \leftrightarrow A[d]$ 
P1.5    $A[d] \leftarrow p$ 

```

et on se sert des **sentinelles** qui sont maintenant en place $A[g], A[d - 1]$:

```

P2'  $i \leftarrow g; j \leftarrow d - 1$ 
P5'   do  $j \leftarrow j - 1$  while  $A[j] > p$ 

```

Profondeur de la pile d'exécution. En une implantation efficace, on se sert de la position terminale du deuxième appel récursif (Ligne Q4).

```

Algo QUICKSORT_ITER( $A[0..n - 1], g, d$ ) // tri de  $A[g..d]$ 
QI1 while  $g < d$  do
QI2    $i \leftarrow \text{PARTITION}(A, g, d)$ 
QI3   QUICKSORT_ITER( $A, g, i - 1$ )
QI4    $g \leftarrow i + 1$  // boucler au lieu de l'appel récursif

```

La profondeur de la pile d'exécution dépend donc du nombre d'appels récursifs en Ligne QI3 ce qui est $\Theta(n)$ au pire (p.e., on a $i = d$ toujours). On peut facilement modifier le code pour toujours faire l'appel récursif avec le plus court entre $A[g..i - 1]$ et $A[i + 1..d]$ qui assure que la profondeur maximale est $\Theta(\log n)$.

12.5 Moyen cas

Théorème 12.1. 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 12.2. 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 12.1. Par Lemme 12.2,

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

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,

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

où $H_n = \sum_{i=1}^n 1/i = \ln n + \gamma + o(1)$ est le n -ème nombre harmonique ($\gamma = 0.5772\dots$ est la constante d'Euler-Mascheroni).

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 !

12.6 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. Ici, on se sert plutôt de la partition autour d'un pivot pour achever un temps de calcul linéaire *en moyen cas* (voir Théorème 12.3 ci-bas), mais $\Theta(n^2)$ au pire. En pratique, l'algorithme par partition est souvent plus performant que l'algorithme avec un temps linéaire théoriquement garanti.

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 if  $d \leq g+1$  then                                     // cas de base : 1 ou 2 éléments
S2   if  $d = g+1$  et  $A[d] < A[g]$  then échanger  $A[g] \leftrightarrow A[d]$            // 2 éléments
S3   return  $A[k]$ 
S4  $i \leftarrow \text{PARTITION}(A, g, d)$ 
S5 if  $k = i$  then return  $A[k]$                                      // on l'a trouvé
S6 if  $k < i$  then return SELECTION( $A, g, i-1, k$ )                 // continuer à la gauche
S7 if  $k > i$  then return 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 12.3. Avec un pivot aléatoire, algorithme SELECTION fait $(2 + o(1))n$ comparaisons en moyenne.

Exercice 12.3. Démontrer Théorème 12.3.