

# Calcul déterministe de la médiane

Benjamin Hellouin

Cormen, 9.3

On s'intéresse à la résolution du problème de sélection : trouver, dans un tableau, le  $i$ -ème plus petit élément ( $i$  étant donné en entrée). On montre que le paradigme diviser-pour-régner peut être utilisé pour donner un algorithme en temps linéaire, donc plus efficace que de trier le tableau puis prendre le  $i$ -ième élément. Une application majeure de ce résultat est la recherche d'un pivot pour l'algorithme de tri rapide : on peut par exemple rechercher la médiane basse du tableau, i.e. le  $\lfloor \frac{n}{2} \rfloor$ -ième élément, pour garantir un temps d'exécution en  $O(n \log n)$  dans le pire cas (et non pas en moyenne).

L'algorithme procède comme suit :

- Diviser le tableau d'entrée en  $\lfloor \frac{n}{5} \rfloor$  tableaux de 5 éléments, avec éventuellement un dernier tableau de  $\leq 5$  éléments ;
- Trier chaque tableau et en extraire la médiane (en temps constant) ;
- Appliquer récursivement cet algorithme pour trouver la médiane de ces médianes ;
- Partitionner le tableau autour de cette dernière médiane, obtenant un tableau gauche de taille  $k - 1$  ;
  - si  $k = i$ , renvoyer la médiane trouvée ;
  - si  $i < k$ , appliquer l'algorithme sur le tableau de gauche et  $i$  ;
  - si  $k < i$ , appliquer l'algorithme sur le tableau de droite et  $k - i$ .

Pour faire l'analyse de complexité, on regarde le nombre d'éléments plus grands que l'élément renvoyé  $x$  : pour au moins la moitié des tableaux, 3 éléments au moins sont plus grands que  $x$ , en excluant celui contenant  $x$  (seulement 2) et le tableau excédentaire, soit

$$3 \left( \left\lceil \frac{1}{2} \left\lfloor \frac{n}{5} \right\rfloor \right\rceil - 1 \right) + 2 \geq \frac{3n}{10} - 3.$$

et symétriquement, de sorte que l'algorithme est rappelé récursivement sur un tableau de taille au plus  $\frac{7n}{10} + 3$ . Ceci nous permet d'étudier la complexité de l'algorithme.

$$\begin{aligned} T(n) \leq & O(n) && \text{(étapes 1,2,4)} \\ & + T(\lfloor n/5 \rfloor) && \text{(étape 3)} \\ & + T(\frac{7n}{10} + 3) && \text{(étape 4 bis, ter)} \end{aligned}$$

Le théorème de Master nous indique que cette récurrence implique un temps d'exécution linéaire. On peut s'en convaincre en supposant que le terme non récursif est majoré par  $an$ , et en prouvant par récurrence forte que  $T(n) < cn$  pour

un certain  $c$ . La relation de récurrence devient, par hypothèse de récurrence :

$$T(n) \leq an + cn/5 + c(7n/10 + 3) = (a + c/5 + 7c/10)n + 3c$$

soit  $T(n) \leq cn$  si  $an - cn/10 + 3c < 0$ . Si on prend  $c > 20a$ , ceci devient  $-cn/20 + 3c < 0$ , ce qui est vrai pour  $n > 60$ . en prenant  $c$  assez grand pour que  $T(n) \leq cn$  pour  $n \leq 60$ , la récurrence est établie et on prouve que l'algorithme de sélection est en temps linéaire.

**Application.** On peut choisir le pivot de l'algorithme de tri rapide en utilisant l'algorithme de sélection de la médiane décrit ci-dessus, de sorte que  $C(n) = T(n) + 2C(n/2)$ , ce qui suffit à obtenir un temps  $O(n \log n)$  dans le pire cas, ce qui est la meilleure borne asymptotique atteignable. Dans la pratique, rechercher la médiane à chaque étape est trop laborieux. On préférera utiliser la structure précédente et choisir pour pivot la médiane des médianes, ce qui conserve la borne asymptototique en  $O(n \log n)$  mais réduit le temps de calcul non récursif (en réduisant la qualité du pivot).