

Recherche du k^{ème} élément

F. Laroussinie

la médiane

Données:


- Un tableau **T** de taille $n \geq 1$
- Des éléments tous distincts deux à deux

Résultat:

l'élément x de T tel que:

$$|\{ y \in T \mid y \leq x \}| = \lceil n/2 \rceil$$

$$|\{ y \in T \mid y > x \}| = \lfloor n/2 \rfloor$$



le problème du «k^{ème} elt»

Données:

- Un tableau **T** de taille $n \geq 1$
- Des éléments tous distincts deux à deux
- Un entier **k**

Résultat:

L'élément x de T tel que:

$$|\{ y \in T \mid y < x \}| = k-1$$

$$|\{ y \in T \mid y > x \}| = n-k$$

6 algorithmes

- ▶ Algo «naif»
- ▶ Algo «naif 2»
- ▶ Algo «select» (quickselect)
- ▶ Algo «select opt»
- ▶ Algo avec des arbres (2 algos)

$|T| = n$

Algo naif

```
def algonatif(T,k):  
    if k > n : erreur  
    for i = 1..k :  
        indmin = indiceMin(T)  
        if i < k : T[indmin] = ∞  
    return T[indmin]
```

$n-1$ comparaisons

Complexité: $O(k.n)$
ou $O(n^2)$ car $k \leq n/2$

Algo (un tout petit peu moins) naif

$|T| = n$

```
def algonatif'(T,k):  
    if k > n : erreur  
    for i = 1..k :  
        indmin = indiceMin(T[1...n-k+2])  
        if i ≤ k-2 : T[indmin] = T[n-k+2+i]  
        else if i == k-1 : T[indmin] = ∞  
    return T[indmin]
```

Exemple: $n=9$ éléments, $k=3$
Le plus petit de 8 éléments ne peut pas être le 3^{ème} plus petit...
C'est soit le plus petit, soit le 2^{ème} plus petit.

NB: le + petit de $n-k+2$ valeurs ne peut pas être le $k^{\text{ème}}$ plus petit des n valeurs !

```
def algonatif'(T,k):  
    if k > n : erreur  
    for i = 1..k :  
        indmin = indiceMin(T[1...n-k+2])  
        if i ≤ k-2 : T[indmin] = T[n-k+2+i]  
        else if i == k-1 : T[indmin] = ∞  
    return T[indmin]
```

$n=20$
 $k=5$

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
4	9	1	8	-2	5	10	14	21	15	7	-4	9	11	13	55	61	-8	6	2

$i=1$ indmin=12

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
4	9	1	8	-2	5	10	14	21	15	7	-8	9	11	13	55	61	-8	6	2

$i=2$ indmin=12

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
4	9	1	8	-2	5	10	14	21	15	7	6	9	11	13	55	61	-8	6	2

$i=3$ indmin= 5

```
def algonatif'(T,k):  
    if k > n : erreur  
    for i = 1..k :  
        indmin = indiceMin(T[1...n-k+2])  
        if i ≤ k-2 : T[indmin] = T[n-k+2+i]  
        else if i == k-1 : T[indmin] = ∞  
    return T[indmin]
```

$n=20$
 $k=5$

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
4	9	1	8	2	5	10	14	21	15	7	6	9	11	13	55	61	-8	6	2

$i=4$ indmin=3

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
4	9	∞	8	2	5	10	14	21	15	7	6	9	11	13	55	61	-8	6	2

$i=5$ indmin=5

resultat = 2

Algo (un tout petit peu moins) naif *complexité*

$|T| = n$

```
def algonatif(T,k):  
    if k > n : erreur  
    for i = 1..k :  
        indmin = indiceMin(T[1...n-k+2])  
        if i ≤ k-2 : T[indmin] = T[n-k+2+i]  
        else if i == k-1 : T[indmin] = ∞  
    return T[indmin]
```

$n-k+1$ comparaisons

Complexité: $O(k.n)$
ou $O(n^2)$ car $k \leq n/2$

Algo naif 2

Complexité: $O(n \log n)$

- Trier $T[1..n]$
- retourner $T[k]$

1er algo bien

k^{eme} élément et TAS

Construire un TAS T avec les n éléments.
Pour $i=1$ à k :
 $x = \text{ExtraireMin}(T)$
Retourner x

Complexité:


- En $O(n)$ pour la construction du tas.
 - $O(\log(n))$ pour l'extraction du min.
- $O(n + k \log(n))$

Algorithme
Select
(ou **quickselect**)

Algorithme select

Basé sur le quicksort («**quickselect**»).

On **pivote** T selon un pivot p:



On continue en cherchant le...

- $k^{\text{ème}}$ élément sur la **partie gauche** si $k < \text{indp} + 1$
- $k - \text{indp} - 1^{\text{ème}}$ élément sur la **partie droite** si $k > \text{indp} + 1$

et on s'arrête si $k = \text{indp} + 1$!

Exemple

T	0						6											17
	7	10	4	8	3	2	12	45	20	15	17	80	71	34	89	30	23	14

$\text{indp} = 6$

- Si $k = 7$, alors le $k^{\text{ème}}$ plus petit est le pivot (ie 12)!
- Si $k < 7$, alors le $k^{\text{ème}}$ plus petit de T est le $k^{\text{ème}}$ plus petit de

7	10	4	8	3	2
---	----	---	---	---	---
- Si $k > 7$, alors le k -ème plus petit de T est le $k - 7^{\text{ème}}$ plus petit de

45	20	15	17	80	71	34	89	30	23	14
----	----	----	----	----	----	----	----	----	----	----

Algorithme select

inv: $k \in \{1, \dots, \text{bd} - \text{bg} + 1\}$
et $\text{bg} \leq \text{bd}$

```

def select(T, k, bg, bd) :
    indp = indicepivot(T, bg, bd)
    rangpivot = indp - bg + 1 → rang du pivot dans T[bg..bd]
    if (k < rangpivot) :
        return select(T, k, bg, indp - 1)
    elif (k > rangpivot) :
        return select(T, k - rangpivot, indp + 1, bd)
    else :
        return T[indp]
    
```

Exercice: vérifier l'invariant...

Pivotage...

```

def indicepivot(T, bg, bd) :
    p = T[bg] → pivot = premier élément
    l = bg + 1
    r = bd
    while (l <= r) :
        while (l <= bd) and (T[l] <= p) : l += 1
        while (T[r] > p) : r -= 1
        if (l < r) :
            T[r], T[l] = T[l], T[r]
            l, r = l + 1, r - 1
    T[r], T[bg] = p, T[r]
    return r
    
```

Algorithme **select**

```
def select(T,k,bg,bd) :
    indp = indicepivot(T,bg,bd)
    rangpivot = indp-bg+1
    if (k<rangpivot) :
        return select(T,k,bg,indp-1)
    elif (k>rangpivot) :
        return select(T,k-rangpivot,indp+1,bd)
    else :
        return T[indp]
```

Complexité: $O(n^2)$

cas pire: recherche du plus petit élément dans T trié dans l'ordre décroissant.

Algorithme **select**

```
def select(T,k,bg,bd) :
    indp = indicepivot(T,bg,bd)
    rangpivot = indp-bg+1
    if (k<rangpivot) :
        return select(T,k,bg,indp-1)
    elif (k>rangpivot) :
        return select(T,k-rangpivot,indp+1,bd)
    else :
        return T[indp]
```

Et en moyenne ?

$C(n,k)$ = coût moyen de de la recherche du k-ème élément dans une zone de taille n.

$$C(n) = \frac{1}{n} \sum_{k=1}^n C(n, k). \rightarrow \text{moyenne sur tous les } k$$

$C(n,k)$ = coût moyen de de la recherche du k-ème élément dans une zone de taille n.

$$C(n, k) = \frac{1}{n} \left(\underbrace{\sum_{i=1}^{k-1} C(n-i, k-i)}_{i \text{ correspond à la pos. du pivot.}} + \underbrace{\sum_{i=k+1}^n C(i-1, k)}_{\text{pivotage}} \right) + \underbrace{n-1}_{\text{pivotage}}$$

le k-eme élément
est à **droite** du pivot

(on cherche le k-i ème
élément à droite)

le k-eme élément
est à **gauche** du pivot

(on cherche le k ème
élément à gauche)

$$C(n) = \frac{1}{n} \sum_{k=1}^n C(n, k).$$

$$C(n, k) = \frac{1}{n} \left(\underbrace{\sum_{i=1}^{k-1} C(n-i, k-i)}_{i \text{ correspond à la pos. du pivot.}} + \sum_{i=k+1}^n C(i-1, k) \right) + \underbrace{n-1}_{\text{pivotage}}$$

d'où:

$$C(n) = \frac{1}{n^2} \left(\underbrace{\sum_{k=1}^n \sum_{i=1}^{k-1} C(n-i, k-i)}_A + \underbrace{\sum_{k=1}^n \sum_{i=k+1}^n C(i-1, k)}_B \right) + n-1$$

A

$$\sum_{k=1}^n \sum_{i=1}^{k-1} C(n-i, k-i) = \begin{aligned} &C(n-1, 1) \quad k=2 \\ &C(n-1, 2) + C(n-2, 1) \quad k=3 \\ &C(n-1, 3) + C(n-2, 2) + C(n-3, 1) \quad k=4 \\ &\vdots \\ &C(n-1, n-1) + C(n-2, n-2) + \dots + C(2, 2) + C(1, 1) \quad k=n \end{aligned}$$

$$\rightarrow C(1, 1) + (C(2, 1) + C(2, 2)) + (C(3, 1) + C(3, 2) + C(3, 3)) + \dots + (C(n-1, 1) + C(n-1, 2) + \dots + C(n-1, n-1))$$

$$= \sum_{i=1}^{n-1} \sum_{k=1}^i C(i, k)$$

$$A : \sum_{k=1}^n \sum_{i=1}^{k-1} C(n-i, k-i)$$

B:

$$\sum_{k=1}^n \sum_{i=k+1}^n C(i-1, k) = \begin{aligned} &C(1, 1) + C(2, 1) + \dots + C(n-1, 1) \quad k=1 \\ &C(2, 2) + C(3, 2) + \dots + C(n-1, 2) \quad k=2 \\ &C(3, 3) + C(4, 3) + \dots + C(n-1, 3) \quad k=3 \end{aligned}$$

//

$$\sum_{i=1}^{n-1} \sum_{k=1}^i C(i, k) = \begin{aligned} &C(1, 1) + C(2, 1) + C(2, 2) + C(3, 1) + C(3, 2) + C(3, 3) + \dots \\ &C(n-1, 1) + C(n-1, 2) + \dots + C(n-1, n-1) \end{aligned}$$

$$B : \sum_{k=1}^n \sum_{i=k+1}^n C(i-1, k)$$

$$A : \sum_{k=1}^n \sum_{i=1}^{k-1} C(n-i, k-i) = \sum_{i=1}^{n-1} \sum_{k=1}^i C(i, k).$$

$$B : \sum_{k=1}^n \sum_{i=k+1}^n C(i-1, k) = \sum_{k=1}^n \sum_{i=k}^{n-1} C(i, k) = \sum_{i=1}^{n-1} \sum_{k=1}^i C(i, k).$$

d'où:

$$\mathcal{C}(n) = \frac{2}{n^2} \left(\sum_{i=1}^{n-1} \sum_{k=1}^i \mathcal{C}(i, k) \right) + n - 1.$$

$$\mathcal{C}(i) = \frac{1}{i} \sum_{k=1}^i \mathcal{C}(i, k) \quad \rightarrow \quad \sum_{k=1}^i \mathcal{C}(i, k) = i \cdot \mathcal{C}(i)$$

$$\mathcal{C}(n) = \frac{2}{n^2} \sum_{i=1}^{n-1} (i \cdot \mathcal{C}(i)) + n - 1$$

Algorithme «Select-opt»

(voir le détail sur la note de synthèse)

$$\mathcal{C}(n) = O(n).$$

C'est efficace !!!

(En moyenne !!)

Algo «select-opt»

(proposé par Blum, Floyd, Pratt, Rivest et Tarjan en 1973)

- ▶ Si n est petit, utiliser l'algo **select**.
- ▶ Sinon:
 - diviser les n éléments en $\lfloor n/5 \rfloor$ blocs B_i de 5 éléments.
 - trouver le médian m_i de chaque B_i
 - trouver le médian M des m_i
 - pivoter le tableau avec M comme pivot
 - continuer dans la bonne partie du tableau (comme dans **select**)...

Idée: garantir que la prochaine étape se fera sur une fraction du tableau initial...

Algo «select-opt»

```
def selectopt(T,k,bg,bd) :
    n = bd - bg + 1
    if (n < 50) : return select(T,k,bg,bd)[0]

    Taux = [T[IndexMedianQuintuplet(T,bg+j*5)] for j = 0... ⌊n/5⌋ - 1]

    M = selectopt(Taux, ⌈|Taux|/2⌉)

    indp = indicepivotfixe(T,M,bg,bd)
    rangpivot = indp - bg + 1

    if (k < rangpivot) : return selectopt(T,k,bg,indp-1)
    elif (k > rangpivot) : return selectopt(T,k-rangpivot,indp+1,bd)
    else :
        return T[indp]
```

IndexMedianQuintuplet(T,i): retourne l'ind. du médian de T[i],...,T[i+4]


«2» appels récursifs à selectopt !

pivotage selon M

Algo «select-opt» - complexité

La complexité de l'algorithme est bonne car le pivot M choisi n'est jamais «trop mauvais»...


Comment évaluer le nb d'éléts $\leq M$ et $\geq M$?



Algo «select-opt» - complexité

La complexité de l'algorithme est bonne car le pivot M choisi n'est jamais «trop mauvais»...

Comment évaluer le nb d'éléts $\leq M$ et $\geq M$?



Algo «select-opt» - complexité

1) $\lfloor n/5 \rfloor = 2p$, $nb_{\leq M} \geq 3p$ $nb_{\geq M} \geq 3(p+1)$

$$p = \frac{1}{2} \lfloor n/5 \rfloor = \lceil \frac{1}{2} \lfloor n/5 \rfloor \rceil$$

$$p+1 = \lceil \frac{1}{2}(2p+1) \rceil = \lceil \frac{1}{2}(\lfloor n/5 \rfloor + 1) \rceil$$

2) $\lfloor n/5 \rfloor = 2p+1$, $nb_{\leq M}, nb_{\geq M} \geq 3(p+1)$

$$p+1 = \lceil \frac{1}{2}(\lfloor n/5 \rfloor) \rceil$$

$$p+1 = \frac{1}{2}(\lfloor n/5 \rfloor + 1) = \lceil \frac{1}{2}(\lfloor n/5 \rfloor + 1) \rceil$$

Conclusion:

$$nb_{\leq M} \geq 3 \lceil \frac{1}{2} \lfloor n/5 \rfloor \rceil$$

$$nb_{\geq M} \geq 3 \lceil \frac{1}{2}(\lfloor n/5 \rfloor + 1) \rceil \geq 3 \lceil \frac{1}{2} \lfloor n/5 \rfloor \rceil$$

Algo «select-opt» - complexité

$$nb_{\leq M}, nb_{\geq M} \geq 3 \lceil \frac{1}{2} \lfloor n/5 \rfloor \rceil$$

comme $\lfloor n/5 \rfloor \geq (n-4)/5$, on a:

$$nb_{\leq M}, nb_{\geq M} \geq 3 \lceil \frac{1}{2} \lfloor n/5 \rfloor \rceil \geq \frac{3}{2} \cdot \lfloor n/5 \rfloor \geq \frac{3n-12}{10} \geq \frac{3n}{10} - 2$$

Les appels récursifs se font donc sur des sous-tableaux de taille $\leq n - 3n/10 + 2$, donc $\leq 7n/10 + 2$.

$$C(n) = C(\lfloor n/5 \rfloor) + C(7n/10 + 2) + O(n)$$

recherche de M

suite du calcul

Algo «select-opt» - complexité

$$C(n) = C(\lfloor n/5 \rfloor) + C(7n/10 + 2) + O(n)$$

Proposition:

Si $t(n) = \sum_i a_i t(n/b_i) + c \cdot n$ avec $\sum_i a_i/b_i < 1$
alors $t(n) = \Theta(n)$

Preuve:

supp. $t(n) \leq \alpha \cdot n$

$$t(n) = \sum a_i t(n/b_i) + c \cdot n \leq \sum a_i \cdot \alpha \cdot n / b_i + c \cdot n = (c + \alpha \sum a_i/b_i) \cdot n$$

$$\text{Et } (c + \alpha \sum a_i/b_i) \leq \alpha \quad \text{si } \alpha \geq \frac{c}{1 - \sum a_i/b_i}$$

Algo «select-opt» - complexité

$$C(n) = C(\lfloor n/5 \rfloor) + C(7n/10 + 2) + O(n)$$

Proposition:

Si $t(n) = \sum_i a_i t(n/b_i) + c \cdot n$ avec $\sum_i (a_i / b_i) < 1$
alors $t(n) = \Theta(n)$

Corollaire: $C(n) = \Theta(n)$

L'algorithme select-opt est en temps linéaire !

(dans le pire cas !)


Algorithme avec des arbres

Algorithme avec des arbres Min

Voir «The Art of Computer Programming», volume 3, D. Knuth.

k^{ème} élément et arbres min

Arbre min:
n=9




arbre binaire parfait...

9 feuilles + 8 noeuds internes numérotés de 1 à 17

calcul: indiquer le numéro de la feuille
de valeur min dans le sous-arbre.

k^{ème} élément et arbres min

structure de données:



Valeur désignée par le noeud i: $T[T[i]]$ si $i < n$, ou $T[i]$ si $i \geq n$.

ou... (pour simplifier !)



Valeur désignée par le
noeud i: $F[T[i]]$



k^{ème} élément et arbres min

Arbre binaire parfait: hauteur $\leq \lceil \log(n) \rceil$

Calculer les n° de feuilles des noeuds internes : **CalculArbre**
n-1 noeuds internes... n-1 comparaisons : $O(n)$!

Changer une valeur d'une feuille et recalculer : **MaJ**
 $O(\log n)$!

idée:

- 1) On fait un **CalculArbre** pour trouver le min...
- 2) Et k-1 mises à jour (après extraction du min précédent).


k^{ème} élément et arbres min

```
def CalculArbre(T,F,n):
    for i = n-1..1 :
        if (F[T[2i]] <= F[T[2i+1]]) : T[i] = T[2i]
        else : T[i] = T[2i+1]
```

noeuds 1...n-1 : noeuds internes

```
def MaJ(T,v,nf,F):
    F[nf] = v
    i = nf
    while (i/2 >= 1):
        i = i/2
        if (F[T[2i]] <= F[T[2i+1]]) : T[i] = T[2i]
        else : T[i] = T[2i+1]
```

v: nouvelle valeur
nf: numéro de la feuille



k^{ème} élément et arbres min

Algo-kpp (V[1...n],k) :

- 1) appliquer **CalculArbre** sur un arbre avec n-k+2 val:
V[1]... V[n-k+2]
- 2) Pour $i = 1$ à $k-2$:
2') Appliquer **MaJ**(T,V[n-k+2+i],T[1],F)
- 3) Renvoyer le 2^{ème} plus petit élément de l'arbre.

NB: le + petit de n-k+2 valeurs
ne peut pas être le k^{ème} + petit des
n valeurs !

- 1) MaJ(T,∞,T[1],F)
- 2) retourner F[T[1]]

k^{ème} élément et arbres min

Complexité:

$$O(n-k + (k-1) \log(n-k+2))$$

CalculArbre


k-1 MaJ

k^{ème} élément et arbres min

Le cas des quintuplets. Par ex:

4	10	3	12	8
---	----	---	----	---

ici $n-k+2 = 4$



Total = 6 comparaisons suffisent pour trouver le median de 5 ele^{ts}.

Conclusion 1


naif	naif 2	select	select opt	arbres min et tas
$O(k.n)$ $O(n^2)$	$O(n.\log n)$	$O(n^2)$	$O(n)$	$O(n+k.\log(n))$

Test...

Nb de
comparaisons

$k \in \{1, \dots, n/2\}$


(50 tests par taille...)



Nb de
comparaisons

$k \in \{1, \dots, n/8\}$


Graphique 1



Nb de
comparaisons

$k \in \{1, \dots, n/8\}$


tri+k-eme
selectopt
quickselect
arbres min




Nb de
comparaisons

$k \in \{1, \dots, n/2\}$


(tri+k-eme)
select opt
quickselect
arbre min




En temps d'exécution



Go $k = n/10$




Go $k = n/4$




Go $k = 50$

Et sur un tableau déjà trié ?

(oui, ça devient un pb trivial...)



Go $k = n/4$



Go

$k = n/4$