

Επιλογή


Δημήτρης Φωτάκης

Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών
Συστημάτων

Πανεπιστήμιο Αιγαίου

Πρόβλημα Επιλογής

- Πίνακας $A[]$ με n στοιχεία (όχι ταξινομημένος).
Αριθμός k , $1 \leq k \leq n$.
- Υπολογισμός του k -οστού μικρότερου στοιχείου
(στοιχείο θέσης $A[k]$ αν A ταξινομημένος).
 - $k = 1$: ελάχιστο. $k = n$: μέγιστο.
 $k = n / 2$: ενδιάμεσο (median).



Ελάχιστο 1
Μέγιστο 7
Ενδιάμεσο 2

Δομές Δεδομένων

Επιλογή 2

Εφαρμογές

- Υπολογισμός στατιστικού ενδιάμεσου (median).
 - Χρήσιμες πληροφορίες για κατανομή.
 - Ανήκει η Ελλάδα στο φτωχότερο 25% των χωρών ΕΕ;
 - Ανήκει κάποιο φοιτητής στο καλύτερο 10% του έτους του;
- Ισομερής διαίρεση (partition) πίνακα σε ομάδες «ταξινομημένες» μεταξύ τους.
- Ενδιαφέρον αλγοριθμικό πρόβλημα!

Δομές Δεδομένων

Επιλογή 3

Μέγιστο / Ελάχιστο

- Μέγιστο (ελάχιστο) εύκολα σε χρόνο $\Theta(n)$,
με $n - 1$ συγκρίσεις μεταξύ στοιχείων.

```
int maximum(int A[], int n) {
    int max = A[0], i;
    for (i = 1; i < n; i++)
        if (A[i] > max) max = A[i];
    return(max);
}
```
- Μέγιστο και ελάχιστο με $3n / 2 - 2$ συγκρίσεις! **Πώς;**

Δομές Δεδομένων

Επιλογή 4

Κάτω Φράγμα για Μέγιστο

- Κάθε ντετερμινιστικός συγκριτικός αλγόριθμος χρειάζεται $\geq n - 1$ συγκρίσεις για μέγιστο (ελάχιστο).
 - «Πρωτάθλημα» μεταξύ στοιχείων.
 - Σύγκριση στοιχείων : αγώνας όπου κερδίζει μεγαλύτερο.
 - Κάθε «αήττητο» στοιχείο είναι υποψήφιο μέγιστο.
 - Για μοναδικό μέγιστο, πρέπει τα υπόλοιπα να «ηττηθούν».
 - Κάθε αγώνας δίνει ένα «ηττημένο» στοιχείο
 - $\geq n - 1$ αγώνες / συγκρίσεις για μοναδικό μέγιστο.

Δομές Δεδομένων

Επιλογή 5

Επιλογή

- Σε χρόνο $O(n \log n)$ με ταξινόμηση.
- Μέγιστο ($k = 1$), ελάχιστο ($k = n$) : Γραμμικό χρόνο $\Theta(n)$.
- Άλλες τιμές k : χρόνος $O(n \log n)$ ή $O(n)$;
- Επιλογή σε γραμμικό χρόνο με διαίρει-και-βασίλευε βασισμένη σε διαίρεση της quicksort !

Δομές Δεδομένων

Επιλογή 6

Πιθανοτική Quickselect

- **Τυχαίο** στοιχείο διαχωρισμού (pivot).
- Αναδιάταξη και διαίρεση εισόδου σε δύο υπο-ακολουθίες:
 - Στοιχεία αριστερής $[l..q]$ υπο-ακολ. $<$ στοιχείο διαχωρισμού.
 - Στοιχεία δεξιάς $[q+1..r]$ υπο-ακολ. $>$ στοιχείο διαχωρισμού.
- Αν $k \leq q$, αναδρομική λύση ($A[l..q], k$)
 Αν $k > q$, αναδρομική λύση ($A[q+1..r], k - (q - l + 1)$)




Δομές Δεδομένων

Επιλογή 7

Ορθότητα Quickselect

- Τερματισμός : μέγεθος υπο-ακολουθιών $\leq n - 1$.
- Επαγωγικά υποθέτω ότι $1 \leq k \leq \text{right} - \text{left} + 1$.
 - Αν $1 \leq k \leq \text{el}$, δεξιά στοιχεία «αποκλείονται».
 - Αν $\text{el} < k \leq \text{right} - \text{left} + 1$, αριστερά στοιχεία «αποκλείονται» και k μειώνεται αντίστοιχα ($k' = k - \text{el}$).



Δομές Δεδομένων

Επιλογή 8

Χρόνος Εκτέλεσης (χ.π.)

- Χρόνος εκτελ. αναδρομικών αλγ. με διατύπωση και λύση αναδρομικής εξίσωσης λειτουργίας.
- $T(n)$: χρόνος (χ.π.) για επιλογή από n στοιχεία.
- Χρόνος εκτέλεσης **partition**(n στοιχεία) : $\Theta(n)$
- Χειρότερη περίπτωση : ένα στοιχείο «αποκλείεται» σε κάθε διαίρεση!

$$T(n) = \Theta(n) + T(n-1), \quad T(1) = \Theta(1)$$

$$T(n) = \Theta(n) + \Theta(n-1) + \Theta(n-2) + \dots + \Theta(1) = \Theta(n^2)$$

- Πιθανοτικός αλγ.: χειρότερη περίπτωση έχει εξαιρετικά μικρή πιθανότητα να συμβεί (για κάθε είσοδο) !

Δομές Δεδομένων

Επιλογή 9

Χρόνος Εκτέλεσης (μ.π.)

- Τυχαίο στοιχείο σαν στοιχείο χωρισμού (pivot).
- Για κάθε $i \in [n-1]$,

$$\text{πιθανότητα διαίρεσης } (i, n-i) = \frac{1}{n-1}$$

$$S(n) = \Theta(n) + \frac{1}{n-1} \sum_{i=1}^{n-1} S(\max\{i, n-i\})$$
$$= \Theta(n) + \frac{2}{n-1} \sum_{i=n/2}^{n-1} S(i)$$

- Λύση αναδρομής : $S(n) = \Theta(n)$

Δομές Δεδομένων

Επιλογή 10

Χρόνος Εκτέλεσης (μ.π.)

- **Καλή περίπτωση** : διαίρεση ($n/4, 3n/4$) ή καλύτερη.
 - Τουλάχιστον $n/4$ στοιχεία «αποκλείονται».
- Πιθανότητα «καλής περίπτωσης» $\geq 1/2$!
 - Κατά «μέσο όρο», μία «κακή διαίρεση» πριν από «καλή διαίρεση» που μειώνει στοιχεία από n σε $< 3n/4$.

$$S(n) = \Theta(n) + S(3n/4)$$

- Λύση αναδρομής : $S(n) = \Theta(n)$

- Γεωμετρική σειρά :

$$S(n) = \Theta(n) + \Theta(\frac{3}{4}n) + \Theta((\frac{3}{4})^2n) + \Theta((\frac{3}{4})^3n) + \dots + \Theta(1) = \Theta(n)$$

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16

Δομές Δεδομένων

Επιλογή 11

Ντετερμινιστική Επιλογή

- «Καλή διαίρεση» ντετερμινιστικά:
 - Χρήση ρινοτ **κοντά** στο ενδιάμεσο: πρόβλημα επιλογής!
 - Φαύλος κύκλος : γρήγορη επιλογή \rightarrow καλή διαίρεση \rightarrow γρήγορη επιλογή.
- Προσεγγιστική επιλογή : όχι «ενδιάμεσο» αλλά «κοντά στο ενδιάμεσο» για ρινοτ.
 - Επιλογή **κατάλληλου** δείγματος (π.χ. $n/5$ στοιχεία).
 - Ενδιάμεσο δείγματος είναι «κοντά στο ενδιάμεσο» για σύνολο στοιχείων.
 - Αναδρομικά ενδιάμεσο στοιχείο του δείγματος.
 - Ενδιάμεσο δείγματος για ρινοτ εγγυάται «καλή διαίρεση».

Δομές Δεδομένων

Επιλογή 12

Ντετερμινιστική Επιλογή

- Δείγμα: Χωρίζουμε στοιχεία σε 5άδες.
Βρίσκουμε ενδιάμεσο κάθε 5άδας: $n / 5$ στοιχεία.
 - Χρόνος : $\Theta(n)$.
- Αναδρομικά, ενδιάμεσο στοιχείο δείγματος.
 - Χρόνος : $T(n / 5)$
- Διάρθρωση με ενδιάμεσο δείγματος σαν ρινοτ.
 - Χρόνος : $\Theta(n)$.
 - Μεγαλύτερος υποπίνακας $\leq 7n / 10$ στοιχεία.
- Αναδρομική επιλογή: χρόνος $T(7n / 10)$



Δομές Δεδομένων

Επιλογή 13

Ντετερμινιστική Επιλογή


- Χρόνος χειρότερης περίπτωσης:
 $T(n) = \Theta(n) + T(n/5) + T(7n/10)$, $T(1) = \Theta(1)$
- Λύση αναδρομής : $T(n) = \Theta(n)$
- Ντετερμινιστική επιλογή σε γραμμικό χρόνο!

Δομές Δεδομένων

Επιλογή 14

Ενδιάμεσο Δείγματος

- Διάρθρωση με ενδιάμεσο δείγματος σαν ρινοτ.
 - Μεγαλύτερος υποπίνακας $\leq 7n / 10$ στοιχεία.
 - Μικρότερος υποπίνακας $\geq 3n / 10$ στοιχεία.
- Ταξινομούμε 5άδες και βάζουμε σε αύξουσα σειρά των ενδιάμεσων στοιχείων τους (δείγματος).
- Ενδιάμεσος δείγματος στη $(n / 10)$ -οστή στήλη.
- Ενδιάμεσος δείγματος $\geq 3 \times n / 10$ στοιχεία.
Ενδιάμεσος δείγματος $\leq 3 \times n / 10$ στοιχεία.



Δομές Δεδομένων

Επιλογή 15

Σύνοψη

- Γρήγορη επιλογή (quickselect):
 - Πιθανοτικός αλγόριθμος με γραμμικό χρόνο (μ.π.)
 - Ντετερμινιστικός αλγόριθμος με γραμμικό χρόνο (χ.π.)
 - Ντετερμινιστικός αλγόριθμος με «bootstrapping»:
 - Για να βρω ενδιάμεσο για πολλά στοιχεία, βρίσκω ενδιάμεσο για λίγα.
 - Αυτό βοηθάει να βρω ενδιάμεσο για περισσότερα, ...

Δομές Δεδομένων

Επιλογή 16

Ασκήσεις

- Τροποποίηση quicksort ώστε $O(n \log n)$ χρόνο σε χειρότερη περίπτωση. Είναι πρακτικό;
- $T(n) = \Theta(n) + T(n/c) + T(n/d)$, $T(1) = \Theta(1)$
 - $1/c + 1/d < 1 \Rightarrow T(n) = \Theta(n)$
 - $1/c + 1/d = 1 \Rightarrow T(n) = \Theta(n \log n)$
- Στον ντετερμινιστικό αλγόριθμο, χωρίζω στοιχεία σε 3άδες (7άδες). Τι συμβαίνει;
- A και B δύο ταξινομημένοι πίνακες με n στοιχεία ο καθένας. Σε χρόνο $O(\log n)$, το ενδιάμεσο της ένωσης των A και B.