

Quicksort

Δημήτρης Φωτάκης

Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών
Συστημάτων

Πανεπιστήμιο Αιγαίου

Διαίρει-και-Βασίλευε

- Γενική μέθοδος σχεδιασμού αλγορίθμων:
 - **Διαίρεση** σε (≥ 2) υπο-προβλήματα (σημαντικά) μικρότερου μεγέθους.
 - **Ανεξάρτητη** (αναδρομική) επίλυση υπο-προβλημάτων (για μικρά υπο-προβλήματα εφαρμόζουμε στοιχειώδεις αλγορίθμους).
 - **Σύνθεση** λύσης αρχικού προβλήματος από λύσεις υπο-προβλημάτων.
- Ισχυρή μέθοδος, πολλές σημαντικές εφαρμογές!
- (Εύκολη) ανάλυση με **αναδρομικές εξισώσεις**.
- **Ταξινόμηση** : merge-sort, **quicksort**.

Δομές Δεδομένων

Quicksort 2

Quicksort [Hoare, 62]

- Στοιχείο χωρισμού (pivot), π.χ. πρώτο, τυχαίο, ...
- Αναδιάταξη και διαίρεση εισόδου σε δύο υπο-ακολουθίες:
 - Στοιχεία αριστερής υπο-ακολ. < στοιχείο χωρισμού.
 - Στοιχεία δεξιάς υπο-ακολ. > στοιχείο χωρισμού.
- Ταξινόμηση υπο-ακολουθιών αναδρομικά.
- Ακολουθία ταξινομημένη – όχι σύνθεση!


```
quicksort(int A[], int left, int right) {  
    if (left >= right) return; // At most 1 element  
    q = partition(A, left, right);  
    quicksort(A, left, q);  
    quicksort(A, q+1, right); }  
}
```

Δομές Δεδομένων

Quicksort 3

Διαίρεση

- Στοιχείο χωρισμού (pivot), π.χ. **πρώτο**, τυχαίο, ...
- Διαίρεση σε ένα πέρασμα :
 - Σάρωση από αριστερά (με δείκτη i) μέχρι $A[i] \geq \text{pivot}$.
 - Σάρωση από δεξιά (με δείκτη j) μέχρι $A[j] \leq \text{pivot}$.
 - Δεν έχουν εξεταστεί όλα τα στοιχεία ($i < j$): αντιστροφή($A[i], A[j]$) και συνέχεια.
 - Έχουν εξεταστεί όλα: επιστροφή ορίου χωρισμού (δείκτη j).



Δομές Δεδομένων

Quicksort 4

Ανάλυση Διαίρεσης

- Ορθότητα **partition** :
 - Διατηρεί και επεκτείνει αριστερή περιοχή με στοιχεία \leq ρινोट και δεξιά περιοχή με στοιχεία \geq ρινोट.
 - $A[j] \geq$ ρινोट : επέκταση αριστερής περιοχής σταματά.
 - $A[j] \leq$ ρινोट : επέκταση δεξιάς περιοχής σταματά.
 - Ξένες περιοχές : ανημετάθεση στοιχείων και συνέχεια.
 - Επικάλυψη : ολοκλήρωση διαίρεσης.
 - Τελικά τα στοιχεία αριστερά \leq ρινोट και τα στοιχεία δεξιά \geq ρινोट, **όπως απαιτείται**.
- Κάθε περιοχή > 1 στοιχείο. **Quicksort τερματίζει**.
($1 \leq$ σημείο χωρισμού $\leq n - 1$)
 - Απαραίτητα: i και j σταματούν στο ρινोट.

Δομές Δεδομένων

Quicksort 5

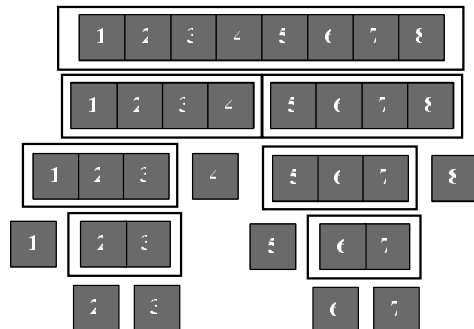
Ανάλυση Διαίρεσης

- Χρόνος εκτέλεσης **partition** :
 - Κάθε στοιχείο συγκρίνεται με ρινोट μία φορά (εκτός από στοιχεία εκατέρωθεν σημείου χωρισμού).
 - Τελικά i και j «δείχνουν» είτε γειτονικές είτε ίδια θέση γιατί όπου πέρασε το i δεν συνεχίζει j .
 - Χρόνος εκτέλεσης **partition για n στοιχεία = $\Theta(n)$** .
- Μετά τη διαίρεση, κανένα στοιχείο δεν αλλάζει «πλευρά» (δηλ. αριστερά μένουν αριστερά, δεξιά μένουν δεξιά).
- Υπάρχουν πολλές άλλες μορφές διαίρεσης, π.χ. ρινोट παίρνει τελική του θέση στον πίνακα, διαίρεση στα τρία, ...

Δομές Δεδομένων

Quicksort 6

Παράδειγμα Quicksort



Δομές Δεδομένων

Quicksort 7

Ορθότητα Quicksort

- Συνέπεια ορθότητας **partition** :
 - Τερματισμός : μέγεθος υπο-ακολουθιών $\leq n - 1$.
 - Ταξινόμηση :
 - Αριστερά στοιχεία \leq ρινोट \leq δεξιά στοιχεία.
 - Επαγωγικά, αριστερή περιοχή και δεξιά περιοχή ταξινομημένες.
 - Συνολικά, πίνακας ταξινομημένος.

Δομές Δεδομένων

Quicksort 8

Χρόνος Εκτέλεσης (χ.π.)

- Χρόνος εκτελ. αναδρομικών αλγ. με διατύπωση και λύση αναδρομικής εξίσωσης λειτουργίας.
- Χρόνος εκτέλεσης **partition**(n στοιχεία) : $\Theta(n)$
- **$T(n)$** : χρόνος (χ.π.) για ταξινόμηση n στοιχείων.
 - **$\Theta(n)$** : αναδιάταξη και διαίρεση εισόδου.
 - **$T(k)$** : ταξινόμηση αριστερού τμήματος (k στοιχεία).
 - **$T(n - k)$** : ταξινόμηση δεξιού τμήματος ($n - k$ στοιχεία).

$$T(n) = \Theta(n) + \max_{1 \leq k \leq n-1} \{T(k) + T(n - k)\}, \quad T(1) = \Theta(1)$$

Δομές Δεδομένων

Quicksort 9

Χρόνος Εκτέλεσης (χ.π.)

$$T(n) = \Theta(n) + \max_{1 \leq k \leq n-1} \{T(k) + T(n - k)\}, \quad T(1) = \Theta(1)$$

- Χειρότερη περίπτωση : $k = 1$ ή $k = n - 1$ (σε κάθε κλήση).
 - Ουσιαστικά δεν γίνεται διαίρεση (μόνο αναδιάταξη) !
 - Partition «βοηθάει ελάχιστα» τον αλγόριθμο.

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

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

- Στιγμιότυπα που quicksort χρειάζεται χρόνο $\Omega(n^2)$;

Δομές Δεδομένων

Quicksort 10

Χρόνος Εκτέλεσης

- **Καλύτερη περίπτωση** : $k = n / 2$ (σε κάθε κλήση).
 - Ουσιαστικά τέλεια διαίρεση !
 - Partition «βοηθάει τα μέγιστα» !
$$T(n) = 2T(n/2) + \Theta(n) \Rightarrow T(n) = \Theta(n \log n)$$
- Αν $\min\{k, n - k\} \geq 3n/4$ (περίπου ίδιο μέγεθος)
$$T(n) = \Theta(n) + T(n/4) + T(3n/4) \Rightarrow T(n) = \Theta(n \log n)$$
- Χειρότερη και καλύτερη περίπτωση σπάνιες !
- Αν τυχαίο στοιχείο ρινότ, πιθανότητα διαίρεσης ($n/4, 3n/4$) ή καλύτερης $\geq 1/2$!

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

Δομές Δεδομένων

Quicksort 11

Πιθανοτική Quicksort

- Τυχαίο στοιχείο σαν στοιχείο χωρισμού (pivot).
- Για κάθε $k \in [n - 1]$, πιθανότητα διαίρεσης ($k, n - k$) = $\frac{1}{n - 1}$

Δομές Δεδομένων

Quicksort 12

Χρόνος Εκτέλεσης (μ.π.)

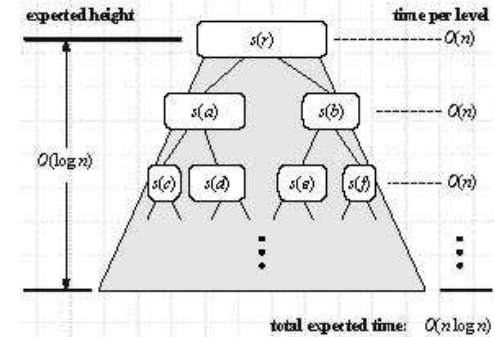
$$S(n) = \Theta(n) + \frac{1}{n-1} \sum_{k=1}^{n-1} [S(k) + S(n-k)]$$
$$= \Theta(n) + \frac{2}{n-1} \sum_{k=1}^{n-1} S(k)$$

- Λύση αναδρομής : $S(n) = \Theta(n \log n)$
Αυτός ο χρόνος εκτέλεσης με μεγάλη πιθανότητα !
- Πιθανότητα διαίρεσης ($n/4, 3n/4$) ή καλύτερης $\geq 1/2$!
 - Κατά «μέσο όρο», κάθε 2 επίπεδα στο δέντρο της αναδρομής, έχουμε «επιτυχημένη» διαίρεση.
 - Σε κάθε επίπεδο, συνολικός χρόνος διαίρεσης $\Theta(n)$.
 - $\Theta(n \log n)$ από «επιτυχημένες» διαιρέσεις + $\Theta(n \log n)$ από «αποτυχημένες» διαιρέσεις.

Δομές Δεδομένων

Quicksort 13

Δέντρο Αναδρομής



Δομές Δεδομένων

Quicksort 14

Χρόνος Εκτέλεσης (μ.π.)

- Πιθανότητα «αποτυχημένες» διαιρέσεις $> c \log n$ είναι εξαιρετικά μικρή !
 - Χρόνος εκτέλεσης $\Theta(n \log n)$ με **μεγάλη πιθανότητα** !
- Μέση περίπτωση δεν εξαρτάται από είσοδο !
Αφορά στη συμπεριφορά του αλγόριθμου.
- Εξαιρετικά μικρή πιθανότητα χειρότερης περίπτωσης.
 - Ανάλυση χειρότερης περίπτωσης δεν έχει νόημα !

Δομές Δεδομένων

Quicksort 15

Σύνοψη

- Γρήγορη ταξινόμηση (quicksort):
 - Πιθανοτικός αλγόριθμος.
 - Χρόνος χειρότερης περ. : $\Theta(n^2)$
 - Χρόνος μέσης περίπτωσης : $\Theta(n \log n)$
 - Χώρος : σχεδόν in-place.
 - Αναδρομή καθυστερεί και απαιτεί μνήμη.
 - Επαναληπτική υλοποίηση.
 - Εύκολη και γρήγορη υλοποίηση.
 - Γρηγορότερος αλγόριθμος στην πράξη (για $n > 30$).

Δομές Δεδομένων

Quicksort 16

Σύνοψη

Αλγόριθμος	Καλύτερη	Μέση	Χειρότερη	Χώρος
BubbleS	$\Omega(n)$	$O(n^2)$	$O(n^2)$	$O(1)$
InsertionS	$\Omega(n)$	$O(n^2)$	$O(n^2)$	$O(1)$
SelectionS	$\Omega(n)$	$O(n^2)$	$O(n^2)$	$O(1)$
HeapS	$\Omega(n \log n)$	$O(n \log n)$	$O(n \log n)$	$O(1)$
MergeS	$\Omega(n \log n)$	$O(n \log n)$	$O(n \log n)$	$O(n)$
QuickS	$\Omega(n \log n)$	$O(n \log n)$	$O(n^2)$?

Δομές Δεδομένων

Quicksort 17

Πιθανοτικοί Αλγόριθμοι

- Ντετερμινιστικοί αλγόριθμοι:
 - Προκαθορισμένη συμπεριφορά για κάθε είσοδο.
 - Υπάρχει χειρότερη περίπτωση και μπορεί να συμβεί.
- Πιθανοτικοί αλγόριθμοι:
 - Συμπεριφορά από είσοδο και τυχαίες επιλογές.
 - Χρήση τυχαιότητας ώστε χειρότερη περίπτωση να συμβαίνει με πολύ μικρή πιθανότητα.
 - Ποια είναι η χειρότερη περ. για πιθανοτική quicksort;
 - Χρόνος (απόδοση) κατά μέση τιμή. Ορθότητα με μεγάλη πιθανότητα.
 - Las-Vegas: αποτέλεσμα σωστό, χρόνος τυχαία μετ/τη.
 - Monte-Carlo: χρόνος προκαθορισμένος, μπορεί λάθος αποτέλεσμα (αλλά με πολύ μικρή πιθανότητα).

Δομές Δεδομένων

Quicksort 18