

Αλγόριθμοι Αναζήτησης

Δημήτρης Φωτάκης

Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών

Εθνικό Μετσόβιο Πολυτεχνείο



Γραμμική Αναζήτηση

- Μοναδικός τρόπος όταν:
 - είτε όχι ταξινομημένος πίνακας,
 - είτε μόνο σειριακή προσπέλαση (π.χ. αρχεία).

```
int linearSearch(int A[], int n, int x) {  
    for (int i = 0; i < n; i++)  
        if (x == A[i]) return(i);  
    return(-1); }
```

- Χρόνος χ.π. / αποτυχημένης αναζήτησης: $\Theta(n)$ (βέλτιστος).
Χρόνος καλύτερης περίπτωσης: $\Theta(1)$.

Γραμμική Αναζήτηση (μ.π.)

- Πιθανότητα αναζήτησης στοιχείου $k = 1 / n$
 - Όλα τα στοιχεία αναζητούνται ισοπίθانا!

- Χρόνος μ.π. = $\sum_{i=k}^n \mathbb{P}[k] \cdot k = \frac{n(n+1)}{2n} = \frac{n+1}{2}$

Γραμμική Αναζήτηση (μ.π.)

- Όχι ισοπίθανη αναζήτηση:
 - Μπροστά στοιχεία με μεγαλύτερη συχνότητα αναζήτησης.
- Δεν γνωρίζουμε συχνότητες:
 - Σταδιακή αναδιοργάνωση : μπροστά στοιχεία που ζητούνται.
 - **Move-to-Front** : χρόνος $\leq 2 \times$ βέλτιστος, λίστα.
 - **Move-Forward** : πίνακας, όχι βελτίωση αν μόνο δύο στοιχεία.
- **Self-adjusting DS**: «προσαρμόζεται» ώστε να είναι ταχύτερη στο μέλλον (βλ. **splay trees**).

0.5	0.3	0.3	0.5
2	3	1	4


Μέσος #συγκρίσεων = **3.8**

Δυαδική Αναζήτηση

- Ταξινόμηση και τυχαία προσπάθεια.
- Χρόνος $O(\log n)$ (βέλτιστος ως προς χ.π.).

```
binarySearch(int A[], int n, int k) {  
    int low = 0, up = n-1, mid;  
    while (low <= up) {  
        mid = (low + up) / 2;  
        if (A[mid] == k) return(mid);  
        else if (A[mid] > k) up = mid - 1;  
        else low = mid + 1;    }  
    return(-1);    }
```

Αναζήτηση **30**:




Ορθότητα

- Αν $A[mid] > k$, k μπορεί να βρίσκεται μόνο αριστερά.
- Αν $A[mid] < k$, k μπορεί να βρίσκεται μόνο δεξιά.
- Σε κάθε επανάληψη, πλήθος υποψήφιων στοιχείων μειώνεται (περίπου) στο μισό :


$$n, \frac{n}{2}, \frac{n}{4}, \dots, \frac{n}{2^l}, \dots, 1 \Rightarrow l \approx \log_2 n$$

- Χρόνος $O(\log n)$: **βέλτιστος** (χειρότερη περίπτωση).




Χρόνος Εκτέλεσης

- **Διαδική αναπαράσταση** θέσεων: κάθε σύγκριση προσδιορίζει ένα bit της θέσης του στοιχείου!
- **Διαδικό δέντρο συγκρίσεων** έχει n φύλλα και $\log_2 n$ ύψος.



Χρόνος Εκτέλεσης

- Για κάθε αλγόριθμο, χωρίς άλλη πληροφορία (π.χ. κατανομή στοιχείων), μία σύγκριση προσδιορίζει ένα bit θέσης στοιχείου.
- Αν δεν γνωρίζουμε κατανομή στοιχείων, κάθε αλγόριθμος αναζήτησης χρειάζεται χρόνο $\Omega(\log n)$ στη χειρότερη περίπτωση.



Αναζήτηση με Παρεμβολή

- Συνήθως έχουμε **κάποια πληροφορία** σχετικά με την **κατανομή** των στοιχείων (π.χ. όταν ψάχνουμε τον **τηλεφωνικό κατάλογο** δεν ανοίγουμε στη μέση).
- Παρεμβολή αξιοποιεί την **πληροφορία κατανομής**. Ταχύτερη (στη μέση περ.) από δυαδική.
 - Αν ξέρουμε κατανομή, **μία σύγκριση** μπορεί να δίνει **περισσότερο από ένα bit** πληροφορίας για θέση στοιχείου.
 - Αναμενόμενη θέση k στο $A[low \dots up]$:
$$pos = low + (k - A[low]) / \begin{matrix} \text{μέση αύξηση} \\ \text{ανά θέση} \end{matrix}$$
 - Κατά τα άλλα ίδια με δυαδική.

Αναζήτηση με Παρεμβολή

- Εκδοχή για **ομοιόμορφη κατανομή** σε διάστημα.
 - Προσαρμόζεται σε **οποιαδήποτε άλλη κατανομή**.


$$pos = low + (k - A[low]) \times \frac{up - low}{A[up] - A[low]}$$

```
int interpolationSearch(int A[], int n, int k) {
    int low = 0, up = n-1, pos;
    while (low <= up) {
        if ((k < A[low]) || (k > A[up])) return(-1);
        pos = low + (int) ((double) (up - low))*
            (((double) (k - A[low])) / (((double) (A[up] - A[low]))));
        if (A[pos] == k) return(pos);
        else if (A[pos] > k) up = pos - 1;
            else low = pos + 1;    }
    return(-1);    }
```


Αναζήτηση με Παρεμβολή

$$pos = low + (k - A[low]) \times \frac{up - low}{A[up] - A[low]}$$

Αναζήτηση **30**:



Αναζήτηση **30**:



Αναζήτηση με Παρεμβολή

- Χρόνος μέσης περίπτωσης : $O(\log \log n)$
 - Αναζήτηση σε 1 τρισεκατ. στοιχεία με 6 συγκρίσεις!
- Χρόνος χειρότερης περίπτωσης : $O(n)$
- Χρόνος χειρότερης περίπτωσης βελτιώνεται με **Διαδική Αναζήτηση με Παρεμβολή**.
- Πρώτη επανάληψη βρίσκει **περιοχή** με ακρίβεια. Επόμενες προσπελάσεις **στην ίδια περιοχή**.
 - Καλή αξιοποίηση της **cache memory**.