

# Problemi najbližih točaka

## Višedimenzionalni “podijeli pa vladaj”

Matea Čelar

PMF-MO

22. siječnja 2019.

# Sadržaj

1. Uvod
2. Problemi najbližih točaka
3. Parovi točaka fiksne udaljenosti
  - 3.1 Implementacija
  - 3.2 Ubrzanje
4. Najbliži par točaka

# Sadržaj

1. Uvod
2. Problemi najbližih točaka
3. Parovi točaka fiksne udaljenosti
  - 3.1 Implementacija
  - 3.2 Ubrzanje
4. Najbliži par točaka

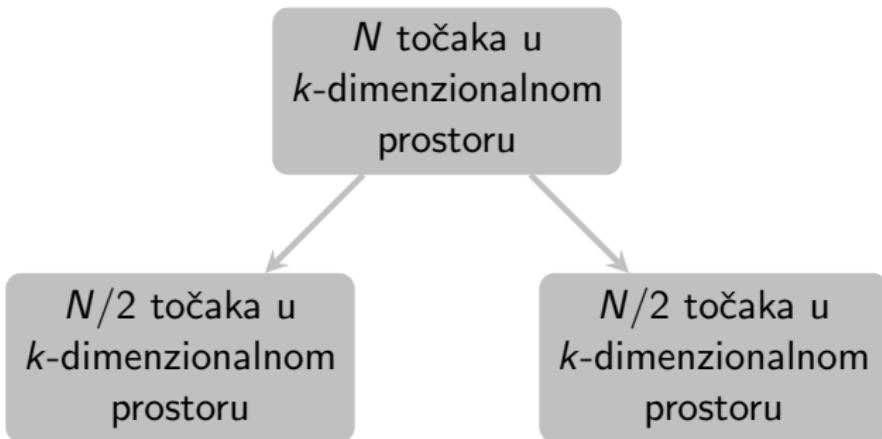
# Uvod

- ▶ Problemi vezani za skupove točaka u višedimenzionalnom prostoru -  $N$  točaka u  $k$ -dimenzionalnom prostoru
- ▶ Takvi problemi se prirodno javljaju u geometriji za  $k = 2, 3$
- ▶ Općenito - statistika, analiza podataka, ...

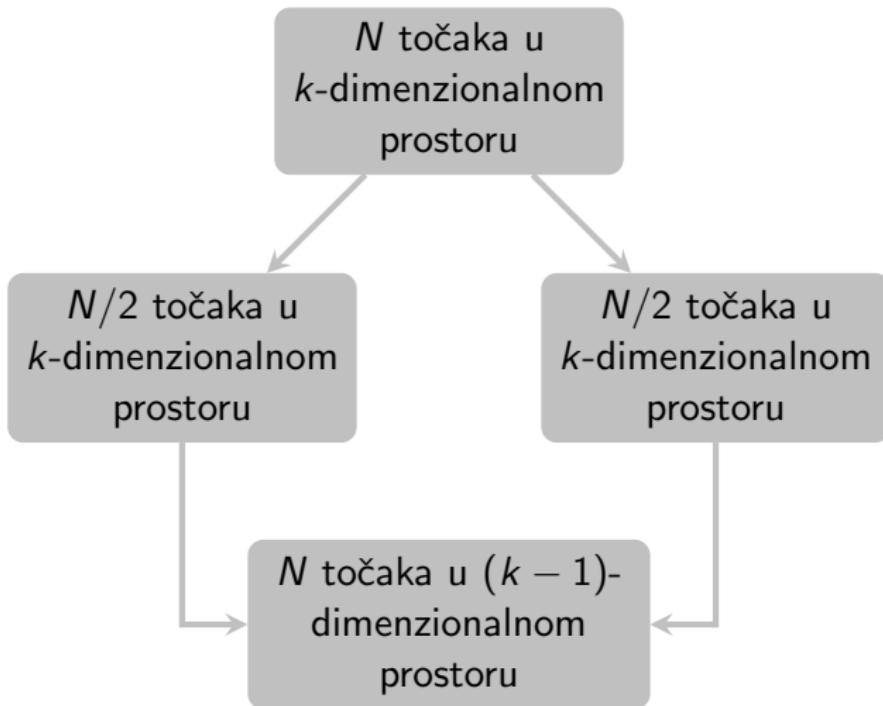
“Podijeli pa vladaj”

$N$  točaka u  
 $k$ -dimenzionalnom  
prostoru

“Podijeli pa vladaj”



“Podijeli pa vladaj”



## “Podijeli pa vladaj”

Da bismo riješili problem za  $N$  točaka u  $k$ -dimenzionalnom prostoru, najprije rekurzivno riješimo dva problema za  $N/2$  točaka u  $k$ -dimenzionalnom prostoru, i zatim rekurzivno riješimo još jedan problem za  $N$  točaka u  $(k - 1)$ -dimenzionalnom prostoru.

# Sadržaj

1. Uvod

2. Problemi najbližih točaka

3. Parovi točaka fiksne udaljenosti

3.1 Implementacija

3.2 Ubrzanje

4. Najbliži par točaka

# Problemi najbližih točaka

- ▶ Problemi vezani za udaljenost ( "blizinu" ) točaka u prostoru
- ▶ Mjera udaljenosti - standardna euklidska metrika u  $\mathbb{R}^k$
- ▶ Možemo promatrati i druge metrike

# Sadržaj

1. Uvod
2. Problemi najbližih točaka
3. Parovi točaka fiksne udaljenosti
  - 3.1 Implementacija
  - 3.2 Ubrzanje
4. Najbliži par točaka

## Parovi točaka fiksne udaljenosti

- ▶ dan je skup  $S$  od  $N$  točaka u  $\mathbb{R}^k$
- ▶ ispisati sve parove točaka iz  $S$  čija je udaljenost manja ili jednaka od  $d > 0$
- ▶  $S$  ima gomilište - složenost  $\mathcal{O}(N^2)$
- ▶ promatramo *raspršene* skupove:

# Parovi točaka fiksne udaljenosti

- ▶ dan je skup  $S$  od  $N$  točaka u  $\mathbb{R}^k$
- ▶ ispisati sve parove točaka iz  $S$  čija je udaljenost manja ili jednaka od  $d > 0$
- ▶  $S$  ima gomilište - složenost  $\mathcal{O}(N^2)$
- ▶ promatramo *raspršene* skupove:

## Definicija 1

Za skup  $S \subseteq \mathbb{R}^k$  kažemo da je **raspršen** ako postoji konstante  $C \in \mathbb{N}$  i  $d > 0$  takve da nijedna kugla radijusa  $d$  ne sadrži više od  $C$  točaka iz  $S$ .

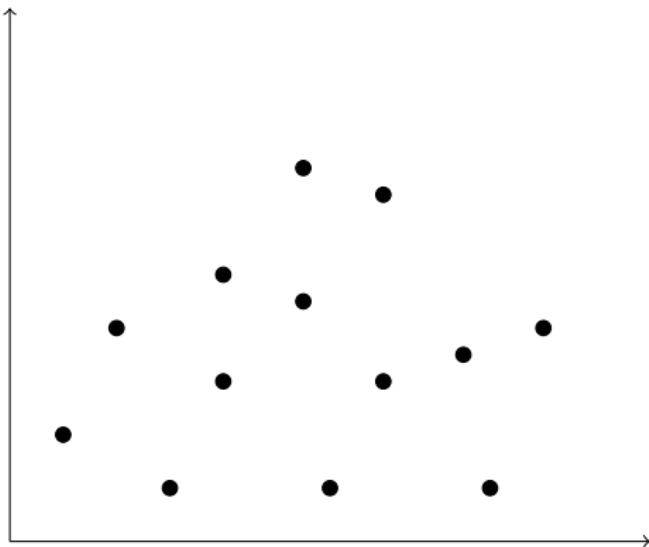
$$k = 1$$

- ▶  $N$  točaka na pravcu, zadani  $c$  i  $d$
  - ▶ dovoljno je za svaku točku provjeriti sljedećih  $c$  točaka

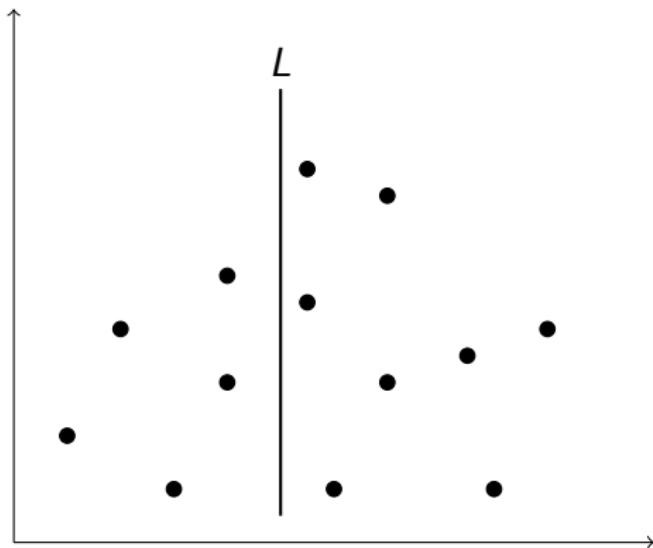


- ▶ sortiranje -  $\mathcal{O}(N \lg N)$
  - ▶ ispitivanje -  $\mathcal{O}(N)$

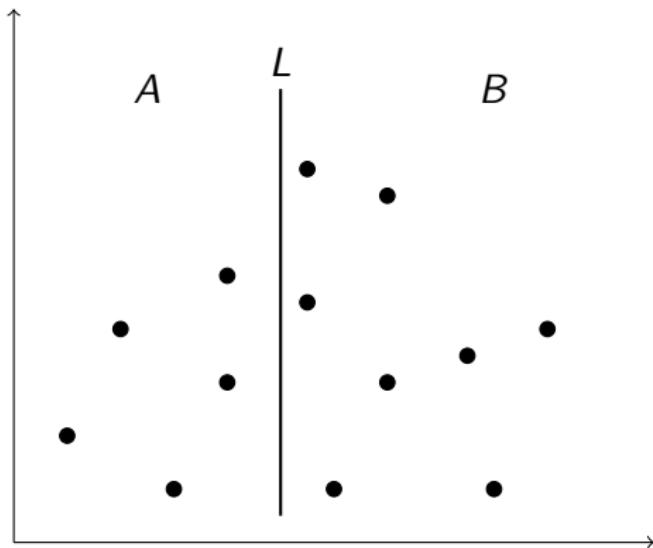
$$k = 2$$



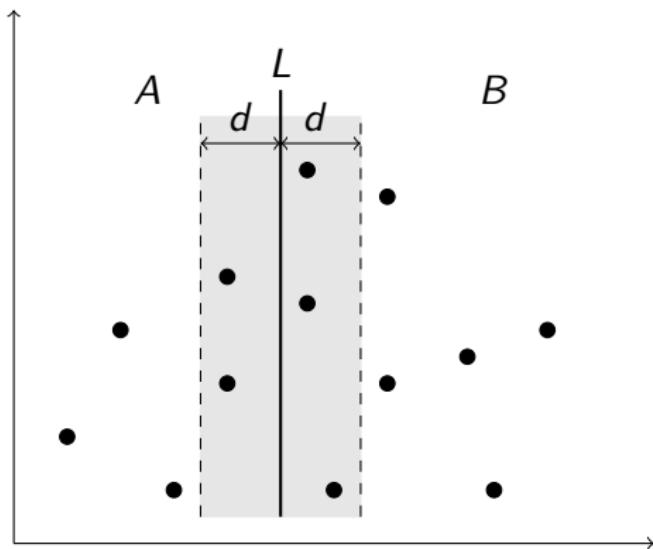
$$k = 2$$



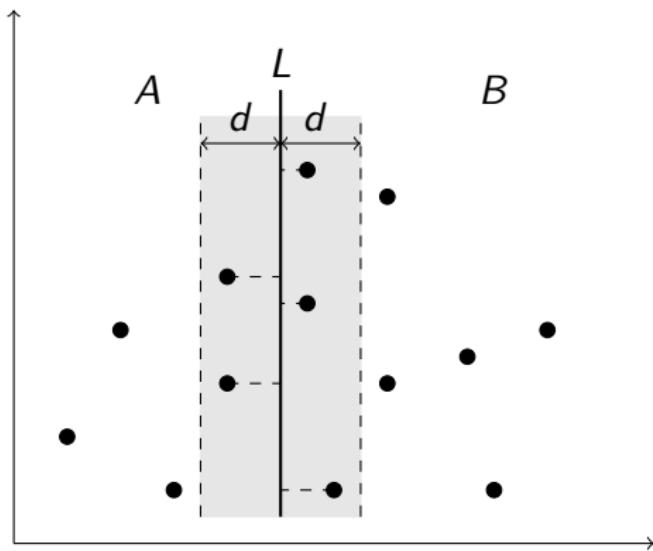
$$k = 2$$



$$k = 2$$



$$k = 2$$



$k = 2$

- ▶ Podijelimo skup  $S$  pravcem  $L$  "otprilike na pola" - partitionirali smo  $S$  na podskupove  $A$  i  $B$
- ▶ U skupovima  $A$  i  $B$  pronađemo parove bliskih točaka rekurzivnim pozivom algoritma
- ▶ Još treba pronaći parove kod kojih je jedna točka u  $A$ , a druga u  $B$
- ▶ Svi takvi parovi nalaze se unutar pruge širine  $2d$  oko  $L$

$k = 2$

Projiciramo točke iz pruge na  $L$

- ▶ projekcija čuva raspršenost
- ▶ udaljenost projiciranih točaka je manja ili jednaka originalnoj udaljenosti

Tražimo parove bliskih (projiciranih) točaka na pravcu

- ▶ složenost  $\mathcal{O}(N \lg N)$
- ▶ ako smo sortirali točke na početku (npr. leksikografski), složenost je  $\mathcal{O}(N)$
- ▶ treba još provjeriti da su točke prije projekcije bile bliske, te da je jedna točka iz  $A$ , a druga iz  $B$

$$k = 2$$

Dobivamo rekurziju

$$T(N) = T(\lfloor N/2 \rfloor) + T(\lceil N/2 \rceil) + \mathcal{O}(N)$$

čije rješenje je

$$T(N) = \mathcal{O}(N \lg N).$$

$$k = 3$$

- ▶ Podijelimo skup  $S$  ravnom  $L$  na podskupove  $A$  i  $B$  otprilike jednake veličine
- ▶ Rekurzivno nađemo parove bliskih točaka u  $A$  i  $B$
- ▶ Treba naći parove kod kojih je jedna točka iz  $A$ , a druga iz  $B$ 
  - sve točke čija je udaljenost od  $L$  manja ili jednaka  $d$  projiciramo na  $L$  i rješavamo analogni problem u dimenziji  $k = 2$
- ▶ Dobivamo rekurziju

$$T(N) = T(\lfloor N/2 \rfloor) + T(\lceil N/2 \rceil) + \mathcal{O}(N \lg N)$$

čije rješenje je

$$T(N) = \mathcal{O}(N \lg^2 N).$$

- ▶ Analogno postupamo i za dimenzije  $k > 3$
- ▶ Matematičkom indukcijom dobivamo da je složenost algoritma za prostor dimenzije  $k$  jednaka

$$T(N) = \mathcal{O}(N \lg^{k-1} N)$$

# Implementacija

```
ulaz: Niz tocka S sortiran leksikografski
izlaz: Parovi tocka cija je udaljenost manja ili jednaka d

nadjiParove (S)
    ako u S postoje barem dvije tocke
        M = medijan tocka u S obzirom na antileksikografski uredjaj

        za svaku tocku T iz S
            ako je |T.y - M.y| <= d
                stavi T u A
            inace stavi T u B

        nadjiParove (A)
        nadjiParove (B)

        za svaku tocku T iz S
            ako je |T.y - M.y| <= d
                stavi T u L

        za svaku tocku T iz L
            za svaku tocku P od sljedecih c tocka
                ako je dist(T, P) <= d i ako je
                    (( T ∈ A i P ∈ B ) ili ( T ∈ B i P ∈ A ))
                        ispisi (T, P)
```

# Implementacija

```
ulaz: Niz tocka S sortiran leksikografski
izlaz: Parovi tocka cija je udaljenost manja ili jednaka d

nadjiParove (S)
    ako u S postoje barem dvije tocke
        M = medijan tocka u S obzirom na antileksikografski uredjaj

        za svaku tocku T iz S
            ako je (T.y < M.y) ili (T.y = M.y i T.x < M.x)
                stavi T u A
            inace stavi T u B

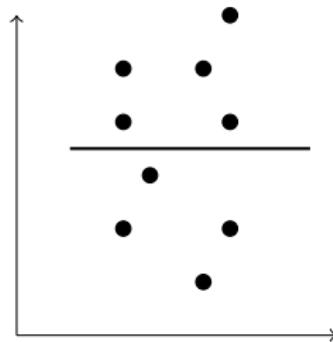
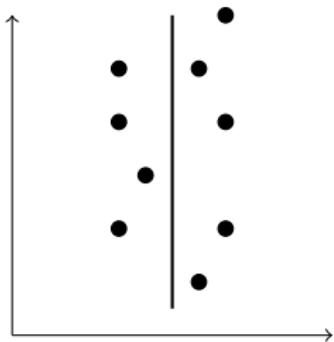
        nadjiParove (A)
        nadjiParove (B)

        za svaku tocku T iz S
            ako je |T.y - M.y| <= d
                stavi T u L

        za svaku tocku T iz L
            za svaku tocku P od sljedecih c tocka
                ako je dist(T, P) <= d i ako je
                    (( T ∈ A i P ∈ B ) ili ( T ∈ B i P ∈ A ))
                        ispisi (T, P)
```

# Može li brže?

- ▶ Dobrim odabirom pravca (hiperravnine)  $L$  možemo značajno smanjiti broj točaka koje treba projicirati
- ▶ Na taj način posljednji korak algoritma možemo provesti u vremenu manjem od linearog



Može se pokazati da vrijedi sljedeće:

### Teorem

Za svaki raspršen skup točaka  $S$  u  $k$ -dimenzionalnom prostoru postoji hiperravnina  $L$  sa sljedećim svojstvima:

- (i) moguće je pronaći  $L$  u linearном vremenu
- (ii)  $L$  dijeli skup  $S$  otprilike na pola
- (iii) točaka udaljenih od  $L$  za  $\leq d$  ima najviše  $\mathcal{O}(N^{1-1/k})$ .

Korištenjem “dobre” hiperravnine, algoritam zadovoljava rekurziju

$$T_k(N) = T_k(\lfloor N/2 \rfloor) + T_k(\lceil N/2 \rceil) + \mathcal{O}(N),$$

čijim rješavanjem dobivamo vremensku složenost

$$T_k(N) = \mathcal{O}(N \lg N).$$

# Sadržaj

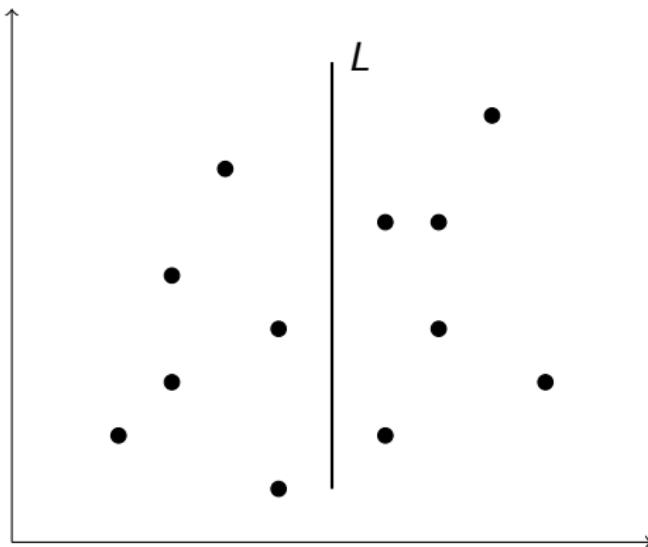
1. Uvod
2. Problemi najbližih točaka
3. Parovi točaka fiksne udaljenosti
  - 3.1 Implementacija
  - 3.2 Ubrzanje
4. Najbliži par točaka

## Najbliži par točaka

- ▶ Dan je skup  $S$  od  $N$  točaka u  $\mathbb{R}^k$
  - ▶ Treba naći najbliži par točaka iz skupa  $S$
- 
- ▶  $k = 1$  - sortiranje i sekvencijalno pretraživanje, složenost  $\mathcal{O}(N \lg N)$
  - ▶  $k \geq 2$  - višedimenzionalni “podijeli pa vladaj”

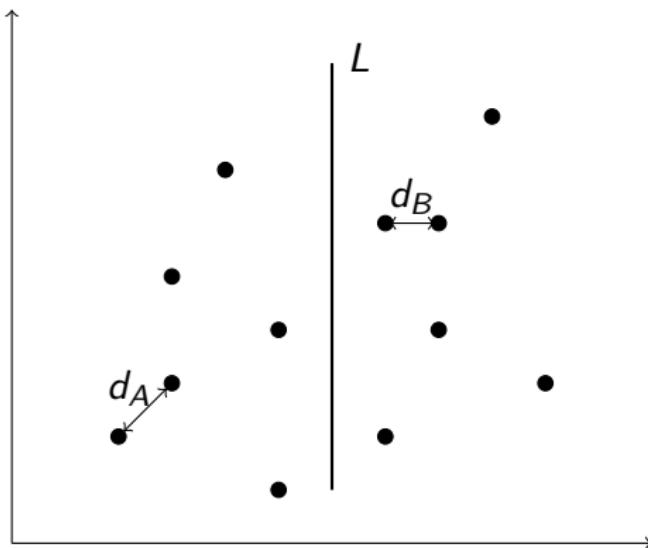
## Najbliži par točaka, $k = 2$

- ▶ skup  $S$  podijelimo pravcem  $L$  na podskupove  $A$  i  $B$
- ▶ rekurzivno nađemo najbliži par točaka u  $A$  i  $B$ ; označimo odgovarajuće minimalne udaljenosti sa  $d_A$  i  $d_B$



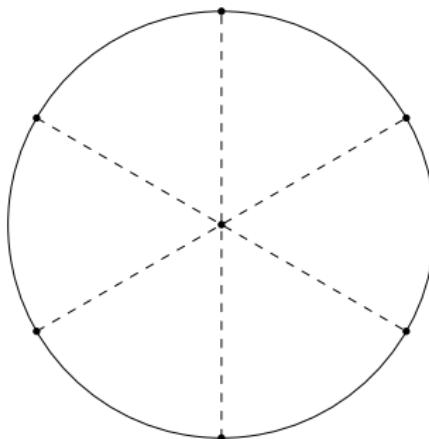
## Najbliži par točaka, $k = 2$

- ▶ skup  $S$  podijelimo pravcem  $L$  na podskupove  $A$  i  $B$
- ▶ rekurzivno nađemo najbliži par točaka u  $A$  i  $B$ ; označimo odgovarajuće minimalne udaljenosti sa  $d_A$  i  $d_B$



## Najbliži par točaka, $k = 2$

- ▶ Ovo inducira raspršenost u  $A$  i  $B$  - svaka kugla polumjera  $d_A$  sadrži najviše 7 točaka iz  $A$  i svaka kugla polumjera  $d_B$  sadrži najviše 7 točaka iz  $B$ , pa svaka kugla polumjera  $d = \min\{d_A, d_B\}$  sadrži najviše 14 točaka iz  $S$



## Najbliži par točaka, $k = 2$

- ▶ Još treba provjeriti postoji li par točaka čija je udaljenost manja od  $d$  takav da je jedna točka iz  $A$ , a druga iz  $B$
- ▶ Točke iz pruge širine  $2d$  oko  $L$  projiciramo na  $L$  i provodimo treći korak prethodnog algoritma, uz potrebne dodatne provjere
- ▶ Složenost (bez početnog sortiranja) je

$$T(N) = \mathcal{O}(N \lg^2 N)$$

## Najbliži par točaka

U višim dimenzijama postupak je analogan:

- ▶ podijelimo  $S$  hiperravninom  $L$  na skupove  $A$  i  $B$
- ▶ rekurzivno nađemo najbliži par točaka u  $A$  i  $B$ ; minimalne udaljenosti su  $d_A$  i  $d_B$  redom
- ▶ sve točke udaljene od  $L$  za manje od  $d = \min\{d_A, d_B\}$  projiciramo da  $L$  i tražimo parove točaka udaljenosti  $d$  -  $\mathcal{O}(N \lg N)$

## Najbliži par točaka

Dobivamo rekurziju

$$T_k(N) = T_k(\lfloor N/2 \rfloor) + T_k(\lceil N/2 \rceil) + \mathcal{O}(N \lg N),$$

čije rješenje je

$$T_k(N) = \mathcal{O}(N \lg^2 N).$$

- ▶ Algoritam možemo dodatno ubrzati odabirom “dobre” hiperravnine  $L$  - složenost  $\mathcal{O}(N \lg N)$

# Literatura

-  Jon Louis Bentley, *Multidimensional Divide-and-Conquer*, Communications of the ACM v.23, n.4 (April 1980), p.214-229.