


# KLASTERIRANJE

PRIMJENA  
KRUSKALOVOG  
ALGORITMA



Ana Paliska  
PMF – MO, Zagreb 15.01.2016.



- KLASTERIRANJE:  
opis problema



- KLASTERIRANJE:  
opis problema
- KRUSKALOV ALGORITAM:  
primjena u klasteriranju



- KLASTERIRANJE:  
opis problema
- KRUSKALOV ALGORITAM:  
primjena u klasteriranju
- PRIMJER



- KLASTERIRANJE:  
opis problema
- KRUSKALOV ALGORITAM:  
primjena u klasteriranju
- PRIMJER
- STRUKTURA PODATAKA:  
Union Find



- KLASTERIRANJE:  
opis problema
- KRUSKALOV ALGORITAM:  
primjena u klasteriranju
- PRIMJER
- STRUKTURA PODATAKA:  
Union Find
- REZULTATI



- KLASTERIRANJE:  
opis problema
- KRUSKALOV ALGORITAM:  
primjena u klasteriranju
- PRIMJER
- STRUKTURA PODATAKA:  
Union Find
- REZULTATI



# KLASTERIRANJE: opis problema



# KLASTERIRANJE: opis problema



- problem **grupiranja** objekata u podgrupe (klastere)
- slični objekti u istim klasterima
- *data mining, statistička analiza podataka, strojno učenje, prepoznavanje uzoraka...*



# KLASTERIRANJE: opis problema




- problem **grupiranja** objekata u podgrupe (klastere)
- slični objekti u istim klasterima
- *data mining, statistička analiza podataka, strojno učenje, prepoznavanje uzoraka...*



- **mjera sličnosti** → udaljenost
- **reprezentacija grafom:** objekti su vrhovi povezani bridovima, a težina brida je udaljenost

# KLASTERIRANJE: opis problema


## Klasteriranje s maksimalnim razmakom



# KLASTERIRANJE: opis problema

## Klasteriranje s maksimalnim razmakom

**K FIKSIRAN**




# KLASTERIRANJE: opis problema

## Klasteriranje s maksimalnim razmakom

### K FIKSIRAN

- objekte (iz skupa  $U$ ) želimo razdvojiti u  $k$  klastera
- klaster  $\rightarrow$  komponenta povezanosti




# KLASTERIRANJE : opis problema

## Klasteriranje s maksimalnim razmakom

### K FIKSIRAN

- objekte (iz skupa  $U$ ) želimo razdvojiti u  $k$  klastera
- klaster  $\rightarrow$  komponenta povezanosti
- $k$  – klasteriranje  $\rightarrow$  particija u  $k$  podskupova (klastera)




# KLASTERIRANJE : opis problema

## Klasteriranje s maksimalnim razmakom

### K FIKSIRAN

- objekte (iz skupa  $U$ ) želimo razdvojiti u  $k$  klastera
- klaster  $\rightarrow$  komponenta povezanosti
- **$k$  – klasteriranje**  $\rightarrow$  particija u  $k$  podskupova (klastera)

- **razmak  $k$  – klastera**  
 $\rightarrow$  minimalna udaljenost između bilo kojeg para vrhova koji leže u različitim klasterima
  - minimalna udaljenost između klastera




# KLASTERIRANJE : opis problema

## Klasteriranje s maksimalnim razmakom

### K FIKSIRAN

- objekte (iz skupa  $U$ ) želimo razdvojiti u  $k$  klastera
- klaster  $\rightarrow$  komponenta povezanosti
- **$k$  – klasteriranje**  $\rightarrow$  particija u  $k$  podskupova (klastera)

- **razmak  $k$  – klastera**  
 $\rightarrow$  minimalna udaljenost između bilo kojeg para vrhova koji leže u različitim klasterima
  - minimalna udaljenost između klastera



# KLASTERIRANJE : opis problema

## Klasteriranje s maksimalnim razmakom

- PROBLEM SE SVODI NA
  - pronalazak  $k$  – klastera s maksimalnim razmakom

# KLASTERIRANJE : opis problema

## Klasteriranje s maksimalnim razmakom

- PROBLEM SE SVODI NA
  - pronalazak  $k$  – klastera s **maksimalnim razmakom**
- problem:
  - eksponencijalno mnogo  $k$  - klastera

# KLASTERIRANJE : opis problema

## Klasteriranje s maksimalnim razmakom

- PROBLEM SE SVODI NA
  - pronalazak  $k$  – klastera s **maksimalnim razmakom**

- problem:
  - eksponencijalno mnogo  $k$  - klastera

- pomoć:
  - Kruskalov algoritam

# KRUSKALOV ALGORITAM


## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 – 6	0.16
2 – 3	0.17
1 – 6	0.19
0 – 2	0.26
5 – 6	0.28
1 – 3	0.29
1 – 5	0.32
2 – 6	0.34
4 – 5	0.35
1 – 2	0.36
4 – 6	0.37
0 – 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 – 6	0.16
2 – 3	0.17
1 – 6	0.19
0 – 2	0.26
5 – 6	0.28
1 – 3	0.29
1 – 5	0.32
2 – 6	0.34
4 – 5	0.35
1 – 2	0.36
4 – 6	0.37
0 – 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 – 6	0.16
2 – 3	0.17
1 – 6	0.19
0 – 2	0.26
5 – 6	0.28
1 – 3	0.29
1 – 5	0.32
2 – 6	0.34
4 – 5	0.35
1 – 2	0.36
4 – 6	0.37
0 – 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 – 6	0.16
2 – 3	0.17
1 – 6	0.19
0 – 2	0.26
5 – 6	0.28
1 – 3	0.29
1 – 5	0.32
2 – 6	0.34
4 – 5	0.35
1 – 2	0.36
4 – 6	0.37
0 – 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 – 6	0.16
2 – 3	0.17
1 – 6	0.19
0 – 2	0.26
5 – 6	0.28
1 – 3	0.29
1 – 5	0.32
2 – 6	0.34
4 – 5	0.35
1 – 2	0.36
4 – 6	0.37
0 – 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo

- pohlepni algoritam za traženje minimalnog razapinjućeg stabla




0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

## Minimalno razapinjuće stablo


- pohlepni algoritam za traženje minimalnog razapinjućeg stabla



0 - 6	0.16
2 - 3	0.17
1 - 6	0.19
0 - 2	0.26
5 - 6	0.28
1 - 3	0.29
1 - 5	0.32
2 - 6	0.34
4 - 5	0.35
1 - 2	0.36
4 - 6	0.37
0 - 4	0.38

# KRUSKALOV ALGORITAM

Primjena u klasteriranju




# KRUSKALOV ALGORITAM

Primjena u klasteriranju



# KRUSKALOV ALGORITAM

Primjena u klasteriranju





# KRUSKALOV ALGORITAM

Primjena u klasteriranju



# KRUSKALOV ALGORITAM

Primjena u klasteriranju



# KRUSKALOV ALGORITAM

Primjena u klasteriranju

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

- problem k – klasteriranja svodi se na traženje minimalnog razapinjućeg stabla (MST) pomoću Kruskalovog algoritma

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

- problem k – klasteriranja svodi se na traženje minimalnog razapinjućeg stabla (MST) pomoću Kruskalovog algoritma
- algoritam staje kada nastane k komponenti povezanosti  $C_1, \dots, C_k$

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

- problem k – klasteriranja svodi se na traženje minimalnog razapinjućeg stabla (MST) pomoću Kruskalovog algoritma
- algoritam staje kada nastane k komponenti povezanosti  $C_1, \dots, C_k$
- ekvivalentno izbacivanju k – 1 najtežih bridova iz MST – a dobivenog Kruskalovim algoritmom

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju


- problem k – klasteriranja svodi se na traženje minimalnog razapinjućeg stabla (MST) pomoću Kruskalovog algoritma
- algoritam staje kada nastane k komponenti povezanosti  $C_1, \dots, C_k$
- ekvivalentno izbacivanju k – 1 najtežih bridova iz MST – a dobivenog Kruskalovim algoritmom

### Teorem

*Komponente povezanosti  $C_1, \dots, C_k$  dobivene micanjem k-1 najtežih bridova iz MST – a Kruskalovog algoritma definira k – kluster s maksimalnim razmakom.*


# PRIMJER – rad algoritma

- prepostavimo da je dan skup od 6 objekata koji je prezentiran grafom od **6 vrhova i 15 bridova** (sve udaljenosti su definirane):



# PRIMJER – rad algoritma


1. sortiramo bridove po težini



# PRIMJER – rad algoritma


2. odaberemo broj klastera k

k = 3




# PRIMJER – rad algoritma

3. Kruskalov algoritam dok ne nastanu 3 komponente povezanosti (3 klastera)




# PRIMJER – rad algoritma

3. Kruskalov algoritam dok ne nastanu 3 komponente povezanosti (3 klastera)




# PRIMJER – rad algoritma

3. Kruskalov algoritam dok ne nastanu 3 komponente povezanosti (3 klastera)




# PRIMJER – rad algoritma

3. Kruskalov algoritam dok ne nastanu 3 komponente povezanosti (3 klastera)




# PRIMJER – rad algoritma

3. Kruskalov algoritam dok ne nastanu 3 komponente povezanosti (3 klastera)



# PRIMJER – rad algoritma


3. Kruskalov algoritam dok ne nastanu 3 komponente povezanosti (3 klastera)



# PRIMJER – rad algoritma

4. STOP!


3 komponente povezanosti!



# PRIMJER – rad algoritma


4. STOP!

3 komponente povezanosti!



# PRIMJER – rad algoritma


Razmak? (minimalna udaljenost između bilo koja dva vrha u različitim klasterima)



# PRIMJER – rad algoritma

**Razmak?** (minimalna udaljenost između bilo koja dva vrha u različitim klasterima)

**Sljedeći brid koji bi Kruskalov algoritam dodao!**



# KRUSKALOV ALGORITAM

Primjena u klasteriranju

*Dokaz*

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- neka  $\mathcal{C}$  označava k-klasteriranje  $C_1, \dots, C_k$  dobiveno Kruskalovim algoritmom

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju


### Dokaz

- neka  $\mathcal{C}$  označava k-klasteriranje  $C_1, \dots, C_k$  dobiveno Kruskalovim algoritmom
- tada je razmak (*spacing*) u  $\mathcal{C}$  upravo duljina  $(k - 1)$ . najtežeg brida ( $d^*$ )

# PRIMJER – rad algoritma

**Razmak?** (minimalna udaljenost između bilo koja dva vrha u različitim klasterima)

**Sljedeći brid koji bi Kruskalov algoritam dodao!**



# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- neka  $\mathcal{C}$  označava k-klasteriranje  $C_1, \dots, C_k$  dobiveno Kruskalovim algoritmom
- tada je razmak (*spacing*) u  $\mathcal{C}$  upravo duljina  $(k - 1)$ . najtežeg brida ( $d^*$ )
- pretpostavimo da je  $\mathcal{C}^*$   $(C_{\cdot 1}^*, \dots, C_{\cdot k}^*)$  neko drugo k – klasteriranje različito od  $\mathcal{C}$

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz


- neka  $\mathcal{C}$  označava k-klasteriranje  $C_1, \dots, C_k$  dobiveno Kruskalovim algoritmom
- tada je razmak (*spacing*) u  $\mathcal{C}$  upravo duljina  $(k - 1)$ . najtežeg brida ( $d^*$ )
- pretpostavimo da je  $\mathcal{C}^*$  ( $C_{*1}, \dots, C_{*k}$ ) neko drugo k – klasteriranje različito od  $\mathcal{C}$
- tada mora postojati jedan od klastera  $C_r$  koji nije podskup niti jednog klastera u  $\mathcal{C}^*$  → postoje točke  $p_i$  i  $p_j$  u  $C_r$  koje pripadaju **različitim** klasterima u  $\mathcal{C}^*$  (BSO) u redom  $C_{*s}$  i  $C_{*t}$

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- $p_i$  i  $p_j$  u  $C_r$  koje pripadaju različitim klasterima u  $C^*$  (BSO) u redom  $C^*_s$  i  $C^*_t$




# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- $p_i$  i  $p_j$  u  $C_r$  koje pripadaju različitim klasterima u  $C^*$  (BSO) u redom  $C^*_s$  i  $C^*_t$

- jer  $p_i$  i  $p_j$  pripadaju istoj komponenti  $C_r \rightarrow$  tada je Kruskalov algoritam dodao sve bridove na putu  $P$  od  $p_i$  do  $p_j$  prije zaustavljanja




# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- $p_i$  i  $p_j$  u  $C_r$  koje pripadaju različitim klasterima u  $C^*$  (BSO) u redom  $C^*_s$  i  $C^*_t$

- jer  $p_i$  i  $p_j$  pripadaju istoj komponenti  $C_r \rightarrow$  tada je Kruskalov algoritam dodao sve bridove na putu  $P$  od  $p_i$  do  $p_j$  prije zaustavljanja
- svaki brid na tom putu je duljine najviše  $d^*$




# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- $p_i$  i  $p_j$  u  $C_r$  koje pripadaju različitim klasterima u  $C^*$  (BSO) u redom  $C^*_s$  i  $C^*_t$




- jer  $p_i$  i  $p_j$  pripadaju istoj komponenti  $C_r \rightarrow$  tada je Kruskalov algoritam dodao sve bridove na putu  $P$  od  $p_i$  do  $p_j$  prije zaustavljanja
- svaki brid na tom putu je duljine najviše  $d^*$
- neka je  $p$  prvi vrh u  $P$  koji ne pripada  $C^*_t$  i neka je  $p'$  prvi takav koji ne pripada  $C^*_s$

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- $p_i$  i  $p_j$  u  $C_r$  koje pripadaju različitim klasterima u  $C^*$  (BSO) u redom  $C^*_s$  i  $C^*_t$




- jer  $p_i$  i  $p_j$  pripadaju istoj komponenti  $C_r \rightarrow$  tada je Kruskalov algoritam dodao sve bridove na putu  $P$  od  $p_i$  do  $p_j$  prije zaustavljanja
- svaki brid na tom putu je duljine najviše  $d^*$
- neka je  $p$  prvi vrh u  $P$  koji ne pripada  $C^*_t$  i neka je  $p'$  prvi takav koji ne pripada  $C^*_s$
- $d(p,p') \leq d^* \rightarrow$  razmak u  $C^*$  je najviše  $d(p,p') \leq d^*$

# KRUSKALOV ALGORITAM

## Primjena u klasteriranju

### Dokaz

- $p_i$  i  $p_j$  u  $C_r$  koje pripadaju različitim klasterima u  $C^*$  (BSO) u redom  $C^*_s$  i  $C^*_t$



- jer  $p_i$  i  $p_j$  pripadaju istoj komponenti  $C_r \rightarrow$  tada je Kruskalov algoritam dodao sve bridove na putu  $P$  od  $p_i$  do  $p_j$  prije zaustavljanja
- svaki brid na tom putu je duljine najviše  $d^*$
- neka je  $p$  prvi vrh u  $P$  koji ne pripada  $C^*_t$  i neka je  $p'$  prvi takav koji ne pripada  $C^*_s$
- $d(p,p') \leq d^* \rightarrow$  razmak u  $C^*$  je najviše  $d(p,p') \leq d^*$

Q. E. D.

# **STRUKTURA PODATAKA**

## **Union Find**

# **STRUKTURA PODATAKA**

## **Union Find**

- omogućava efikasnu implementaciju komponenata povezanosti u grafu

# **STRUKTURA PODATAKA**

## **Union Find**

- omogućava efikasnu implementaciju komponenata povezanosti u grafu

**Karakteristike:**

# STRUKTURA PODATAKA

## Union Find

- omogućava efikasnu implementaciju komponenata povezanosti u grafu

### Karakteristike:

- **Find(u)** → za dani vrh u vraća ime komponente u kojoj se vrh u nalazi (**korijen komponente**)
- **Union(A,B)** → spaja dva skupa A i B u jedan skup
- **poboljšanje strukture** → Union(A,B) spaja kraći skup s većim

# **STRUKTURA PODATAKA**

## **Union Find**

0

1

2

3

4

5

6

7

8

9

# STRUKTURA PODATAKA

## Union Find

Union(4,3)

0

1

2

3

4

5

6

7


8

9

# STRUKTURA PODATAKA

## Union Find


Union(4,3)



# STRUKTURA PODATAKA

## Union Find


Union(3,8)



# STRUKTURA PODATAKA

## Union Find


Union(3,8)



# STRUKTURA PODATAKA

## Union Find


Union(6,5)



# STRUKTURA PODATAKA

## Union Find


Union(6,5)



# STRUKTURA PODATAKA

## Union Find


Union(9,4)



# STRUKTURA PODATAKA

## Union Find


Union(9,4)



# STRUKTURA PODATAKA

## Union Find




Union(1,2)



# STRUKTURA PODATAKA

## Union Find




Union(1,2)



# STRUKTURA PODATAKA

## Union Find

Union(2,3)





# STRUKTURA PODATAKA

## Union Find

Union(2,3)


0



# **STRUKTURA PODATAKA**

## **Union Find**


**SLOŽENOST?**



# STRUKTURA PODATAKA

## Union Find

SLOŽENOST?




- Union(A,B) → O(1)

# STRUKTURA PODATAKA

## Union Find

SLOŽENOST?



- Union(A,B) → **O(1)**
- Find(u) → **O(logn)**

# STRUKTURA PODATAKA

## Union Find → primjena u Kruskalovom algoritmu


- problem zatvara li brid  $(u, v)$  ciklus se svodi na provjeru pripadaju li u i v istoj komponenti povezanosti
- $Find(u) == Find(v)?$

# STRUKTURA PODATAKA

## Union Find → primjena u Kruskalovom algoritmu

- problem zatvara li brid  $(u,v)$  ciklus se svodi na provjeru pripadaju li u i v istoj komponenti povezanosti
- $Find(u) == Find(v)?$



CIKLUS!



# STRUKTURA PODATAKA

## Union Find → primjena u Kruskalovom algoritmu


- problem zatvara li brid  $(u,v)$  ciklus se svodi na provjeru pripadaju li u i v istoj komponenti povezanosti
- $Find(u) == Find(v)?$




# STRUKTURA PODATAKA

## Union Find → primjena u Kruskalovom algoritmu

- problem zatvara li brid  $(u,v)$  ciklus se svodi na provjeru pripadaju li u i v istoj komponenti povezanosti
- $Find(u) == Find(v)?$




$O(\log n)!$



# STRUKTURA PODATAKA

## Analiza složenosti k - klasteriranja


- $m \rightarrow$  broj bridova
- $n \rightarrow$  broj vrhova



# **STRUKTURA PODATAKA**

# Analiza složenosti k - klasteriranja

- $m \rightarrow$  broj bridova
  - $n \rightarrow$  broj vrhova




- prvo sortiramo bridove po težini (od najmanjeg prema najvećem)  $\rightarrow O(m \log m)$
  - jer je  $m < n * (n - 1)$   $\rightarrow O(m \log n)$
  - ukupno  $2m$  poziva Find i  $n - 1$  poziva Union operacija

# STRUKTURA PODATAKA

## Analiza složenosti k - klasteriranja

- $m \rightarrow$  broj bridova
- $n \rightarrow$  broj vrhova



# RAZMATRANJE

**Kako odabrat i?**




# RAZMATRANJE

Kako odabrat k?

$$\min_k \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_j\|^2$$

- minimizira se suma kvadrata unutar klastera  
→ ***k-means clustering***



# RAZMATRANJE

Kako odabrat k?


$$\min_k \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_j\|^2$$

- minimizira se suma kvadrata unutar klastera  
→ ***k-means clustering***
- jednostavan pristup:

$$k \approx \sqrt{\frac{n}{2}}$$

# REZULTATI



# REZULTATI

opisno



# REZULTATI

## opisno

### Ulaz:

- 100 slučajno generiranih težinskih neusmjerenih grafova s  $n$  vrhova i  $n * (n - 1) / 2$  bridova
- težine su slučajno generirane (*double* preciznosti)
- $n$  slučajan cijeli broj iz skupa [20, 520]

# REZULTATI

## opisno

### Ulaz:


- 100 slučajno generiranih težinskih neusmjerenih grafova s  $n$  vrhova i  $n * (n - 1) / 2$  bridova
- težine su slučajno generirane (*double* preciznosti)
- $n$  slučajan cijeli broj iz skupa [20, 520]
- za svaki graf mjeri se vrijeme izvršavanja k-klasteriranja (500 iteracija) → uzima se prosjek

$$k = \lfloor \frac{n}{2} \rfloor$$

# REZULTATI

## opisno

frekvencija broja vrhova na uzorku od 100 grafova



# REZULTATI

## opisno


### Izlaz:

- prosječno vrijeme u *ms* potrebno za izvršavanje k-klasteriranja za svaki od 100 grafova
- usporedba prosječnog vremena izvršavanja u ovisnosti o
  - broju vrhova u grafu
  - k
  - broju bridova u grafu
  - mlogn

# REZULTATI

## prikaz


ovisnost prosječnog trajanja traženja k-klastera  
u ovisnosti o broju vrhova



# REZULTATI

## prikaz

ovisnost prosječnog trajanja traženja k-klastera  
u ovisnosti o k




$$k = \lfloor \frac{n}{2} \rfloor$$

# REZULTATI

## prikaz


ovisnost prosječnog trajanja traženja k-klastera  
u ovisnosti o broju bridova



# REZULTATI

## prikaz

ovisnost prosječnog trajanja traženja k-klastera  
u ovisnosti o  $m \log n$  (m broj bridova, n broj vrhova)



# LITERATURA

- *J.Kleinberg, E.Tardos, Algorithm Design, Pearson Education, 2006.*
- *R.Sedewick, K.Wayne, Algorithms, 4th edition,* dostupno na <http://algs4.cs.princeton.edu/home/> , (siječanj 2016.)