

# GRUPIRANJE (KLASTERIRANJE) – PRIMJENA KRUSKALOVOG ALGORITMA

JAKOV KRUNIĆ

SEMINAR IZ KOLEGIJA OBLIKOVANJE I ANALIZA ALGORITAMA

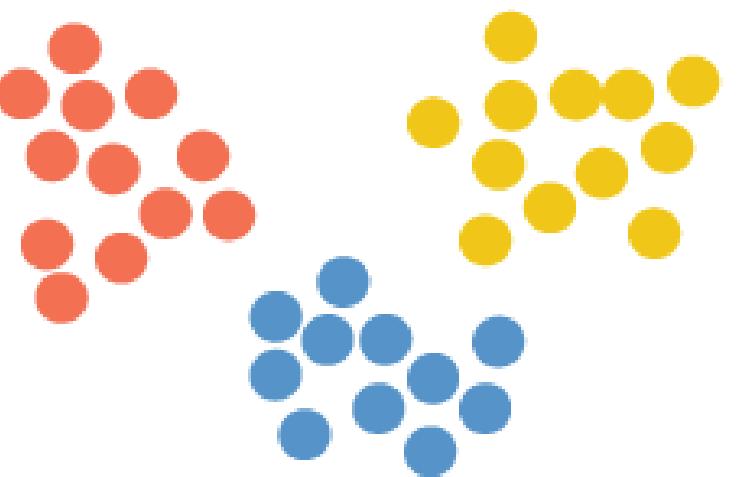
PRIRODOSLOVNO-MATEMATIČKI FAKULTET

ZAGREB, 22.1.2019.

# SADRŽAJ

1. Uvod – što je problem grupiranja?
2. Kruskalov algoritam – opis
3. Primjena Kruskalovog algoritma
4. Implementacija Kruskalovog algoritma i složenost
5. Testiranje
6. Literatura

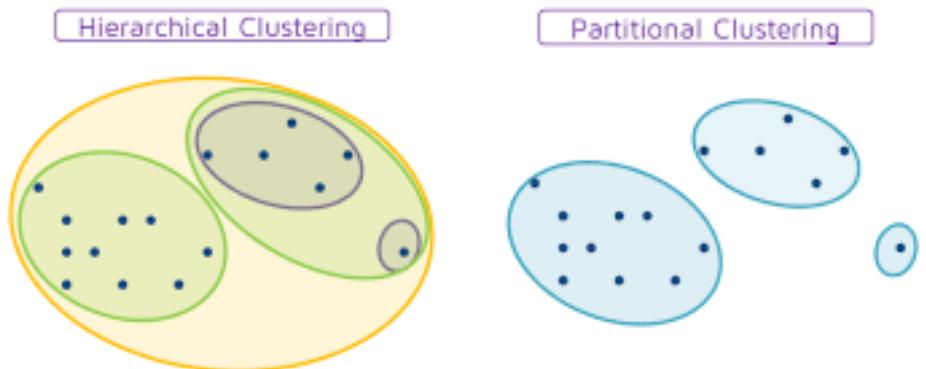
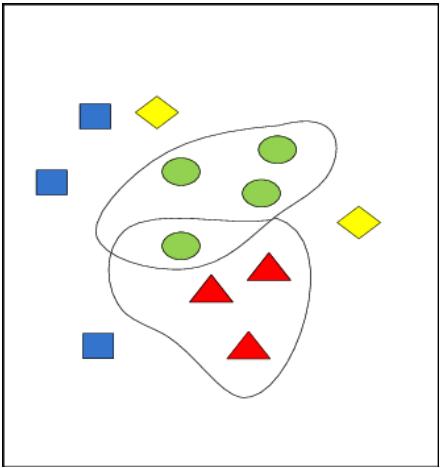
# GRUPIRANJE (CLUSTERING)



- Osnovni problem: Neka je  $S$  neprazan skup.  $S$  treba podijeliti u podskupove (grupe) tako da elementi u svakom podskupu imaju neko zajedničko svojstvo.
- Prirodno je uspostaviti mjeru koja računa koliko je svaki par elemenata sličan.
- Uobičajeni pristup je definiranje funkcije udaljenosti.
- Cilj je da su objekti u istim grupama „bliski”, a objekti u različitim grupama „udaljeni”.

# GRUPIRANJE (CLUSTERING)

- Razne opcije grupiranja: hijerarhijsko grupiranje, grupiranje s preklapanjem, strogo razdvajajuće grupiranje s outlierima (ne pripadaju niti jednom klasteru), strogo razdvajajuće grupiranje.
- Proučavamo strogo razdvajajuće grupiranje: svaki objekt pripada točno jednom klasteru.



# GRUPIRANJE (CLUSTERING)

- Definicija: Neka je  $S$  skup i  $k \in \mathbb{N}$ ,  $k \leq |S|$ .  **$k$ -grupiranje** od  $S$  je particija od  $S$  u  $k$  nepraznih podskupova.
- Definicija: **Razmak (spacing)**  $k$ -grupiranja je najmanja udaljenost između bilo koja dva elementa iz različitih grupa.
- Problem: Za zadani  $k$ , treba pronaći  $k$ -grupiranje s maksimalnim razmakom.

# KRUSKALOV ALGORITAM

- Podsjetnik osnovnih pojmova iz teorije grafova:
  - Graf je uređen par  $(V, E)$  pri čemu je  $V$  skup vrhova, a  $E$  skup bridova (podskup svih dvočlanih podskupova od  $V$ ).
  - Ciklus je put u grafu koji počinje i završava istim vrhom.
  - Graf je povezan ako između svaka dva vrha postoji put.
  - Stablo je povezan graf koji nema ciklus.
  - Razapinjući podgraf  $H$  grafa  $G$  je podgraf od  $G$  takav da je  $V(H) = V(G)$ .
  - Promatrat ćemo težinske grafove: svakom bridu je pridružen realan broj (težina).

# KRUSKALOV ALGORITAM

- Kako pronaći minimalno razapinjuće stablo?
- Odgovor nam daje Kruskalov algoritam.

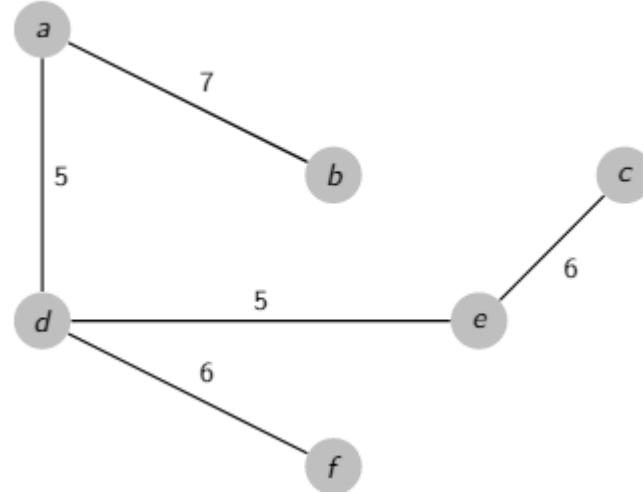
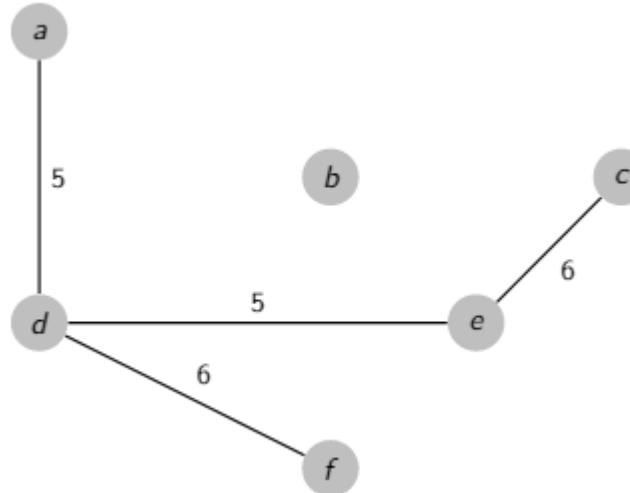
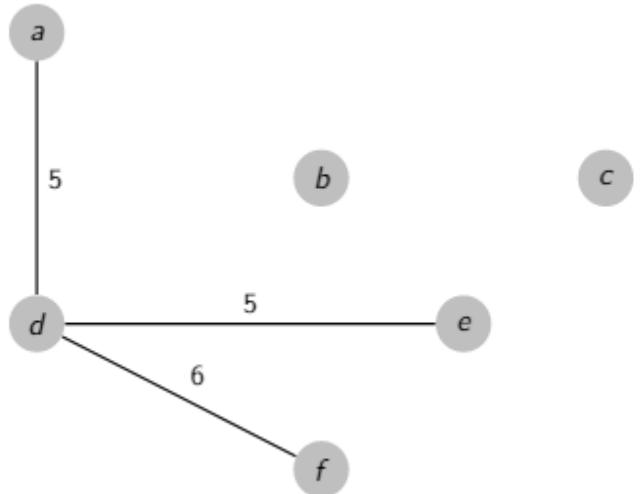
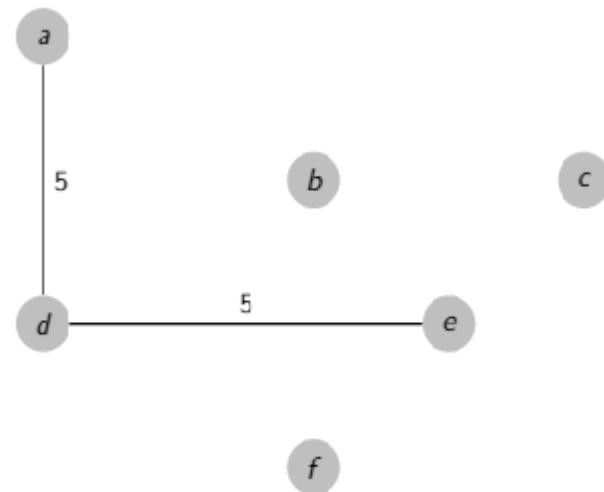
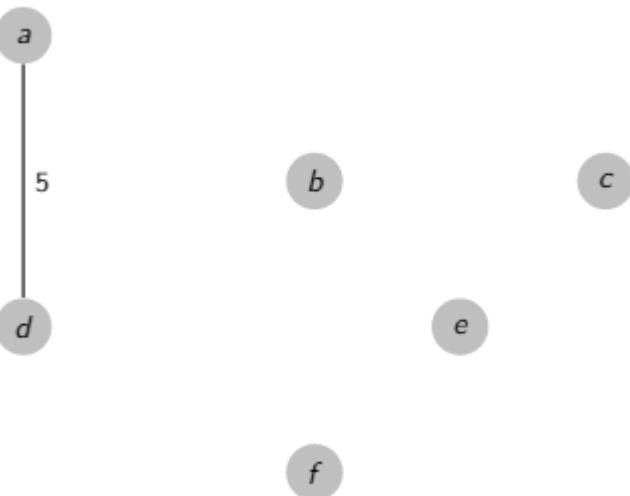
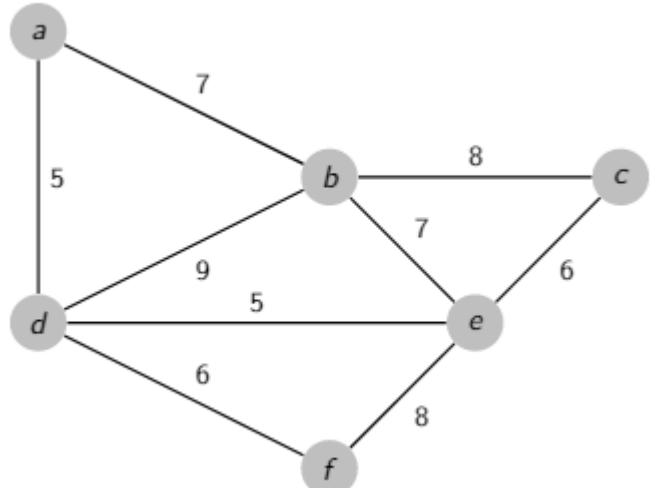
Neka je  $G = (V, E)$  povezan težinski graf. Neka je  $S = \emptyset$ .

Sve dok  $(V, S)$  nije povezan ponavlja:

Odaber i brid  $e \in E \setminus S$  minimalne težine takav da  $S \cup \{e\}$   
nema ciklus

$$S = S \cup \{e\}$$

- **Teorem:** Kruskalov algoritam nalazi optimalno rješenje.
- **Napomena:** Minimalno razapinjuće stablo ne mora biti jedinstveno.



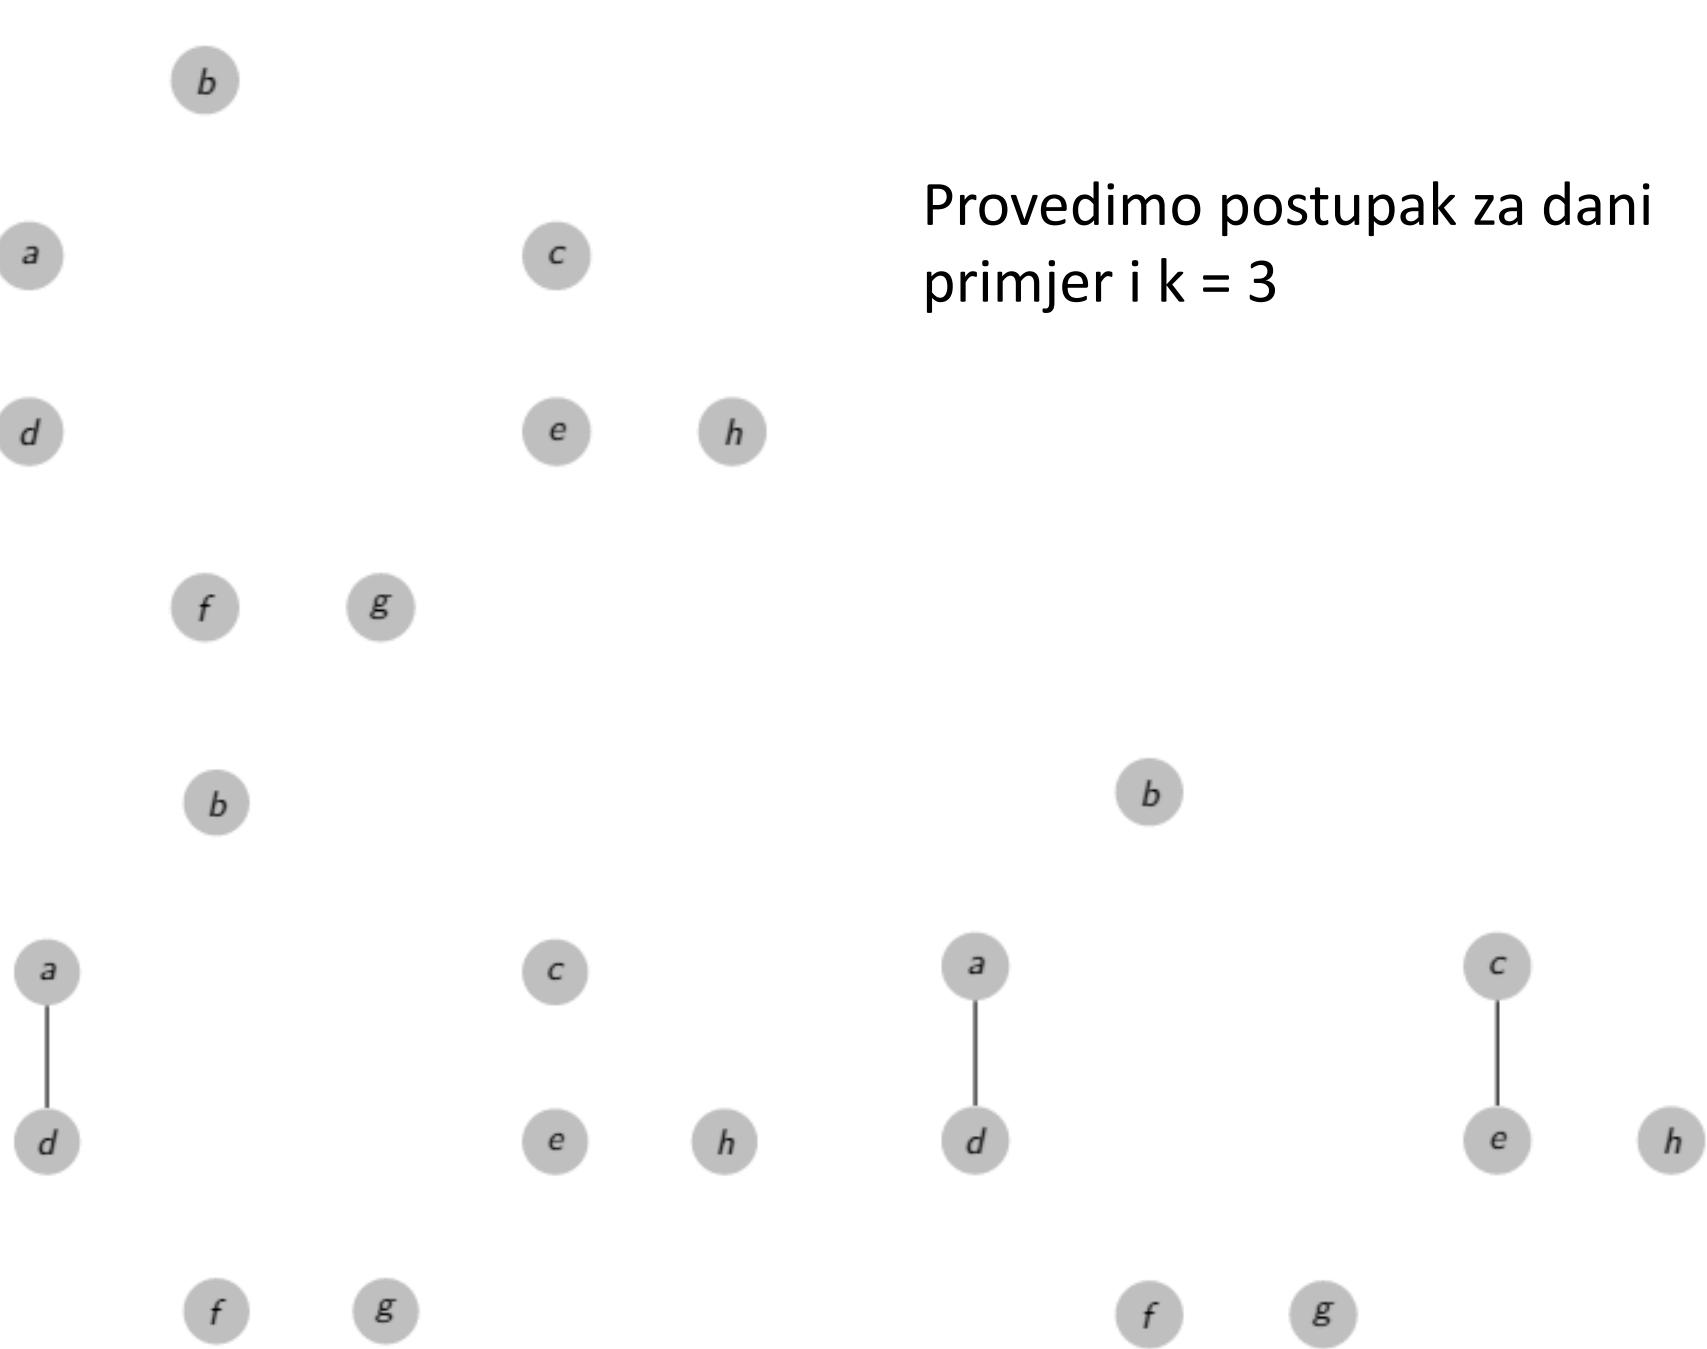
# PRIMJENA KRUSKALOVOG ALGORITMA

- Modeliramo problem pronašlaska  $k$ -grupiranja s maksimalnim razmakom u teoriji grafova.
- Neka je  $S$  skup i  $k \in \mathbb{N}$ ,  $k \leq |S|$ .
- Izgradit ćemo graf  $G$  čiji je skup vrhova  $S$ , a komponente povezanosti grafa će biti klasteri.
- Najprije u skup bridova dodamo brid najmanje težine.

# PRIMJENA KRUSKALOVOG ALGORITMA

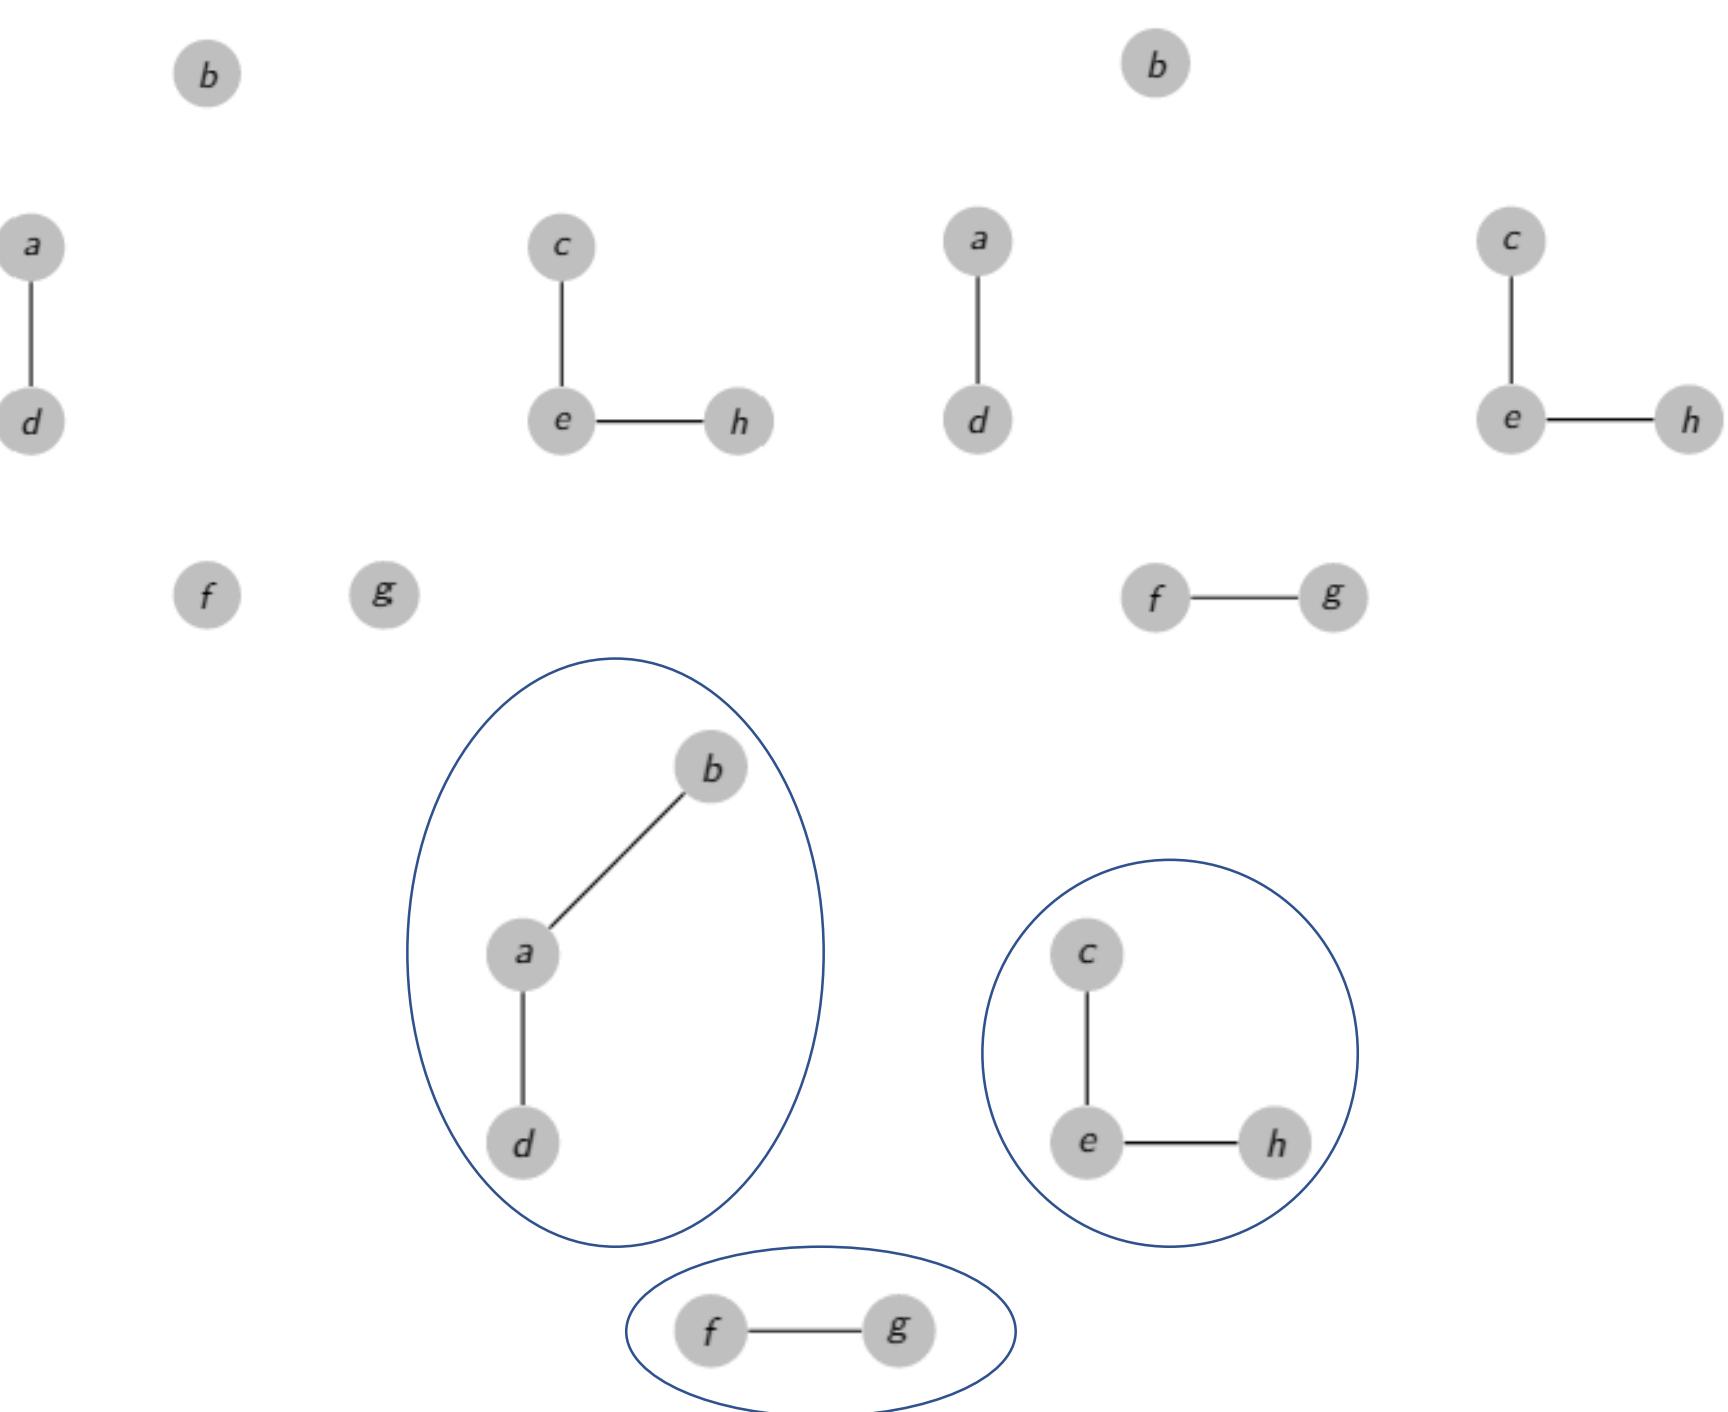
- U svakom koraku biramo brid najmanje težine (od bridova koje još nismo odabrali), uz jedan uvjet.
- Ako je brid  $(p, q)$  najmanje težine, a vrhovi  $p$  i  $q$  se već nalaze u istom klasteru (tj. u istoj komponenti povezanosti), tada taj brid nećemo dodati.
- Na taj način, naš postupak nikad neće stvoriti ciklus, tj.  $G$  će biti unija stabala.
- Gotovi smo kad stvorimo točno k komponenti povezanosti.

(a, d)	1	(a, g)	3.5
(c, e)	1	(c, f)	3.5
(e, h)	1	(c, g)	3.7
(c, h)	1	(b, e)	4
(f, g)	1.5	(f, h)	5
(a, b)	1.7	(b, g)	5.5
(b, d)	2	(c, d)	6
(d, f)	2	(d, e)	7
(e, g)	2	(a, e)	7.5
(g, h)	2.5	(b, h)	8
(b, c)	2.5	(b, f)	9
(a, c)	2.7	(d, h)	11
(a, f)	3	(e, f)	11
(d, g)	3	(a, h)	15



Provđimo postupak za dani primjer i  $k = 3$

(a, d)	1	(a, g)	3.5
(c, e)	1	(c, f)	3.5
(e, h)	1	(c, g)	3.7
(c, h)	1	(b, e)	4
(f, g)	1.5	(f, h)	5
(a, b)	1.7	(b, g)	5.5
(b, d)	2	(c, d)	6
(d, f)	2	(d, e)	7
(e, g)	2	(a, e)	7.5
(g, h)	2.5	(b, h)	8
(b, c)	2.5	(b, f)	9
(a, c)	2.7	(d, h)	11
(a, f)	3	(e, f)	11
(d, g)	3	(a, h)	15



# PRIMJENA KRUSKALOVOG ALGORITMA

- Prethodno opisani postupak je zapravo modificirani Kruskalov algoritam.
- U svakom koraku biramo brid najmanje težine i izbjegavamo cikluse.
- Razlika je u tome što tražimo k-grupiranje, pa zaustavljamo postupak kad dobijemo k komponenti povezanosti.
- Drugim riječima, izvodimo Kruskalov algoritam, ali ga zaustavljamo prije dodavanja posljednjih  $k-1$  bridova.
- Ekvivalentno je da pronađemo minimalno razapinjuće stablo Kruskalovim algoritmom i obrišemo  $k-1$  bridova najveće težine.

- Jesmo li time dobili k-grupiranje s maksimalnim razmakom?

### Teorem

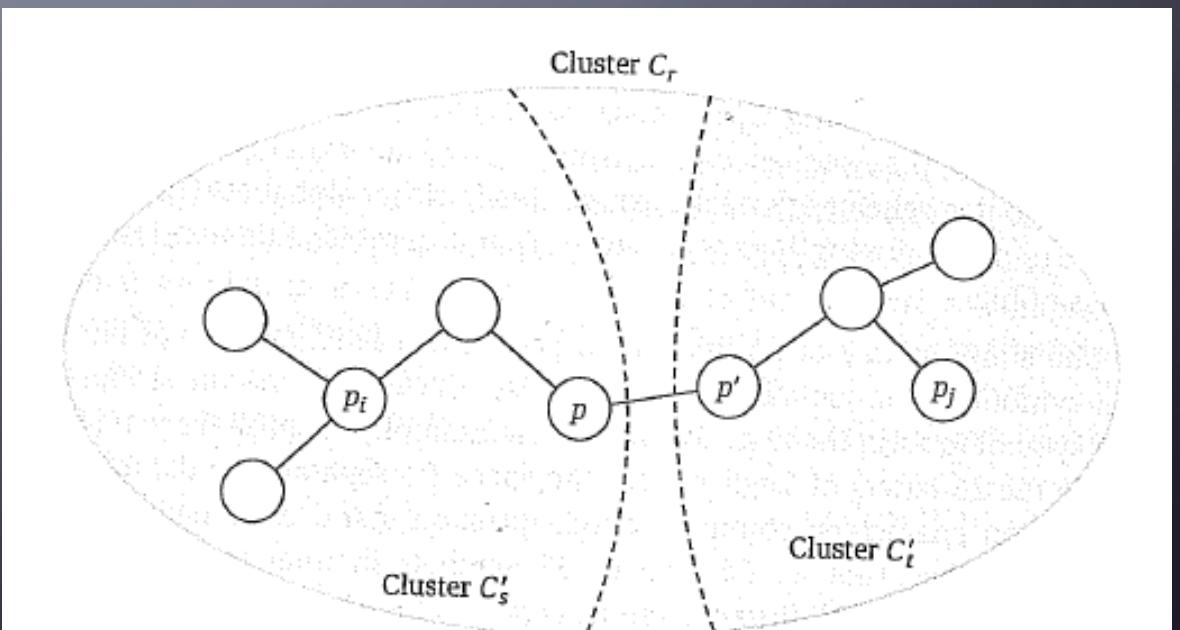
Komponente povezanosti  $C_1, C_2, \dots, C_k$  koje su nastale brisanjem  $k - 1$  bridova najveće težine iz minimalno razapinjućeg stabla čine k-grupiranje s maksimalnim razmakom.

**Dokaz:** Označimo s  $C$  k-grupiranje iz iskaza teorema  $C_1, C_2, \dots, C_k$ . Označimo s  $d^*$  razmak od  $C$ .  $d^*$  je zapravo težina  $(k - 1)$ . najtežeg brida, tj. težina onog brida kojeg bi sljedećeg dodali u naš graf primjenom Kruskalovog algoritma.

Neka je  $C'$  proizvoljno k-grupiranje u klasteru  $C'_1, C'_2, \dots, C'_k$ ;  $C' \neq C$ .

Trebamo pokazati da je razmak od  $C'$  najviše  $d^*$ .

Jer je  $C' \neq C$ , postoji  $r \in \{1, \dots, k\}$  takav da  $C_r$  nije podskup nijednog  $C_s'$  iz  $C'$ . To znači da postoji vrhovi  $p_i, p_j \in C_r$  koji pripadaju različitim klasterima  $C_s'$  i  $C_t'$  iz  $C'$ , tj.  $p_i \in C_s'$  i  $p_j \in C_t'$ ,  $C_s' \neq C_t'$ . Jer su  $p_i, p_j \in C_r$ , postoji put  $P$  od  $p_i$  do  $p_j$  te su svi bridovi iz  $P$  nastali primjenom Kruskalovog algoritma. To znači i da je težina svakog brida iz  $P$  najviše  $d^*$ . Nadalje, znamo da je  $p_i \in C_s'$  i  $p_j \notin C_s'$ ; stoga neka je  $p'$  prvi vrh na putu  $P$  koji ne pripada  $C_s'$  i neka je  $p$  vrh koji je neposredno prije  $p'$  na putu  $P$ .



Brid  $(p, p')$  je očito nastao primjenom Kruskalovog algoritma pa je njegova težina najviše  $d^*$ .  $p$  i  $p'$  pripadaju različitim klasterima iz k-grupiranja  $C'$  i njihova udaljenost je najviše  $d^*$ , a razmak k-grupiranja je po definiciji najmanja udaljenost između bilo koja dva elementa iz različitih klastera, pa zaključujemo da je razmak od  $C'$  najviše  $d^*$ . ■

- **Zaključak:** Problem k-grupiranja s maksimalnim razmakom rješavamo Kruskalovim algoritmom!

# IMPLEMENTACIJA KRUSKALOVOG ALGORITMA

- Sljedeći cilj je efikasna implementacija Kruskalovog algoritma.
- Tražimo strukturu podataka pogodnu za prikaz komponenti povezanosti grafa.
- Cilj je brzo pretraživanje i ažuriranje.
- Struktura podataka bi trebala efikasno spajati dvije komponente u jednu.

# STRUKTURA PODATAKA UNION-FIND

- `MakeUnionFind(S)` uzima skup  $S$  i vraća strukturu Union-Find tako da  $S$  podijeli na jednočlane podskupove.
- `Find(u)` vraća „ime“ skupa koji sadrži  $u$ .
- `Union(A,B)` spaja skupove  $A$  i  $B$  u jedan skup.
- Implementacije su moguće pomoći polja i pomoći pointera.

# STRUKTURA PODATAKA UNION-FIND

- Složenosti implementacije pomoću polja:
  - $\text{MakeUnionFind}(S) - O(n)$
  - $\text{Find}(u) - O(1)$
  - niz k operacija  $\text{Union}(A,B) - O(k \log k)$
- Složenosti implementacije pomoću pointera:
  - $\text{MakeUnionFind}(S) - O(n)$
  - $\text{Find}(u) - O(\log n)$
  - $\text{Union}(A,B) - O(1)$

# IMPLEMENTACIJA KRUSKALOVOG ALGORITMA I VREMENSKA SLOŽENOST

- Promotrimo graf s  $n$  vrhova i  $m$  bridova.
- Prvi korak je sortiranje bridova uzlazno po težini -->  $O(m \log m)$ .
- Znamo da je  $m < n^2$  -->  $O(m \log n)$ .
- Koristimo strukturu Union-Find za prikaz komponenti povezanosti grafa.
- Za brid  $(u, v)$  ispitujemo jesu li  $\text{Find}(u)$  i  $\text{Find}(v)$  jednaki.

# IMPLEMENTACIJA KRUSKALOVOG ALGORITMA I VREMENSKA SLOŽENOST

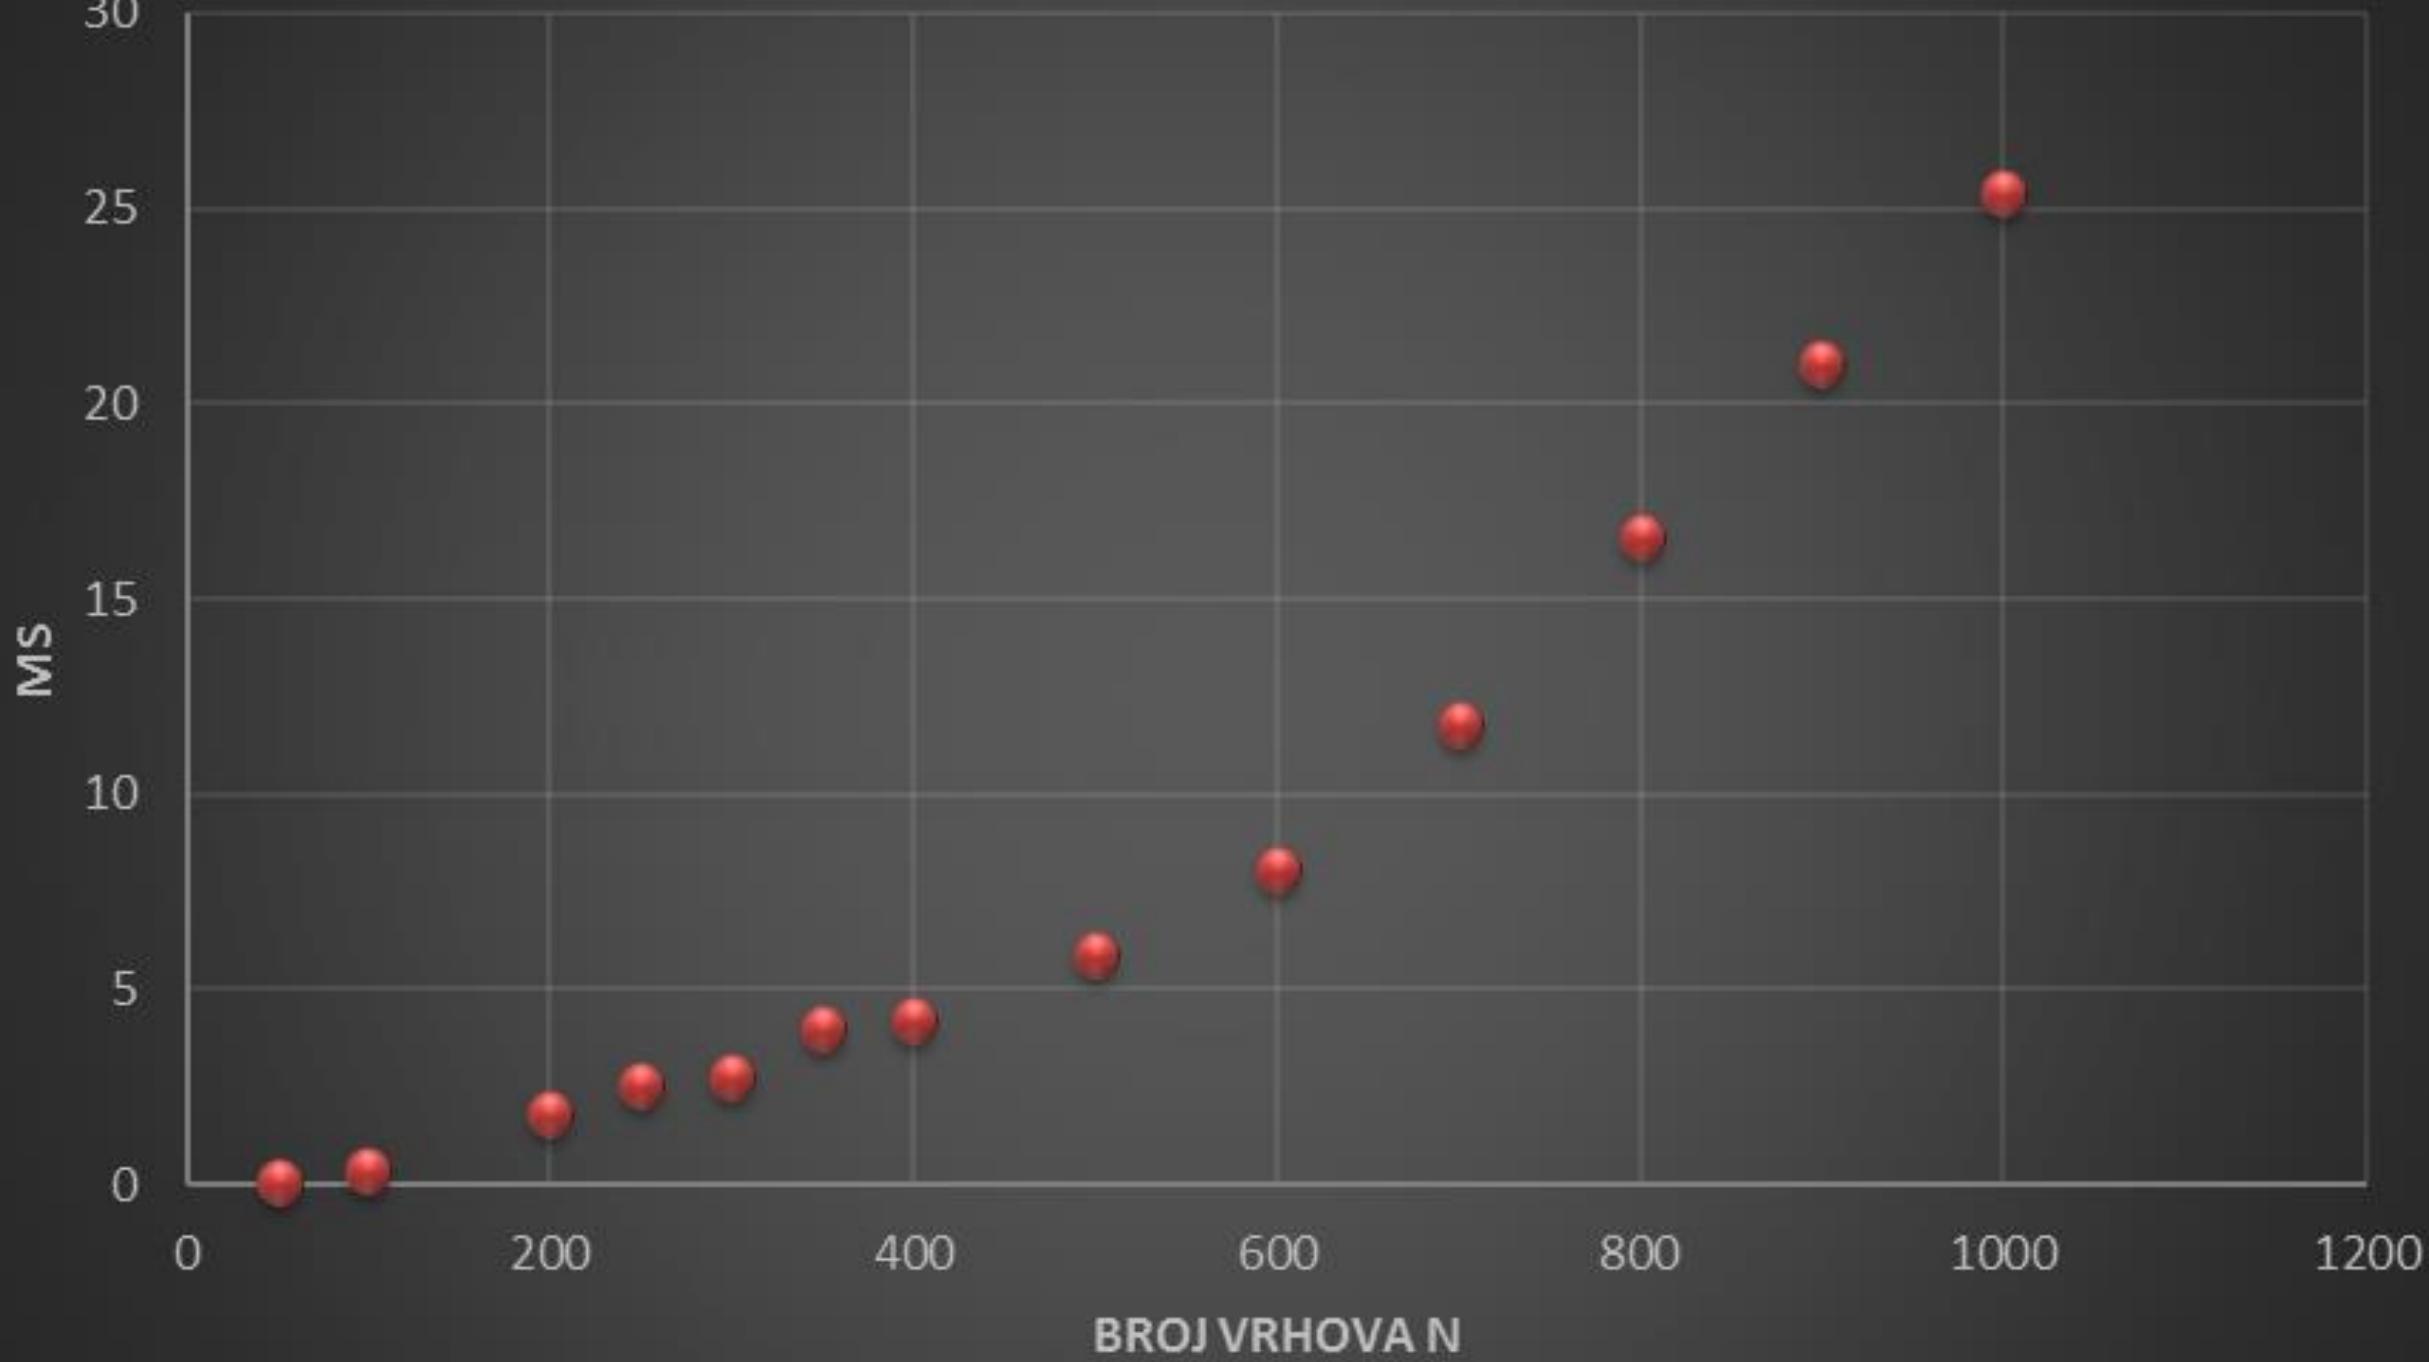
- Union( $\text{Find}(u)$ ,  $\text{Find}(v)$ ) spaja dvije komponente povezanosti.
- Najviše  $2m$  operacija Find.
- Točno  $n - 1$  operacija Union.
- Ukupna vremenska složenost je  $O(m \log n)$  i ona ne ovisi o implementaciji Union-Find strukture.

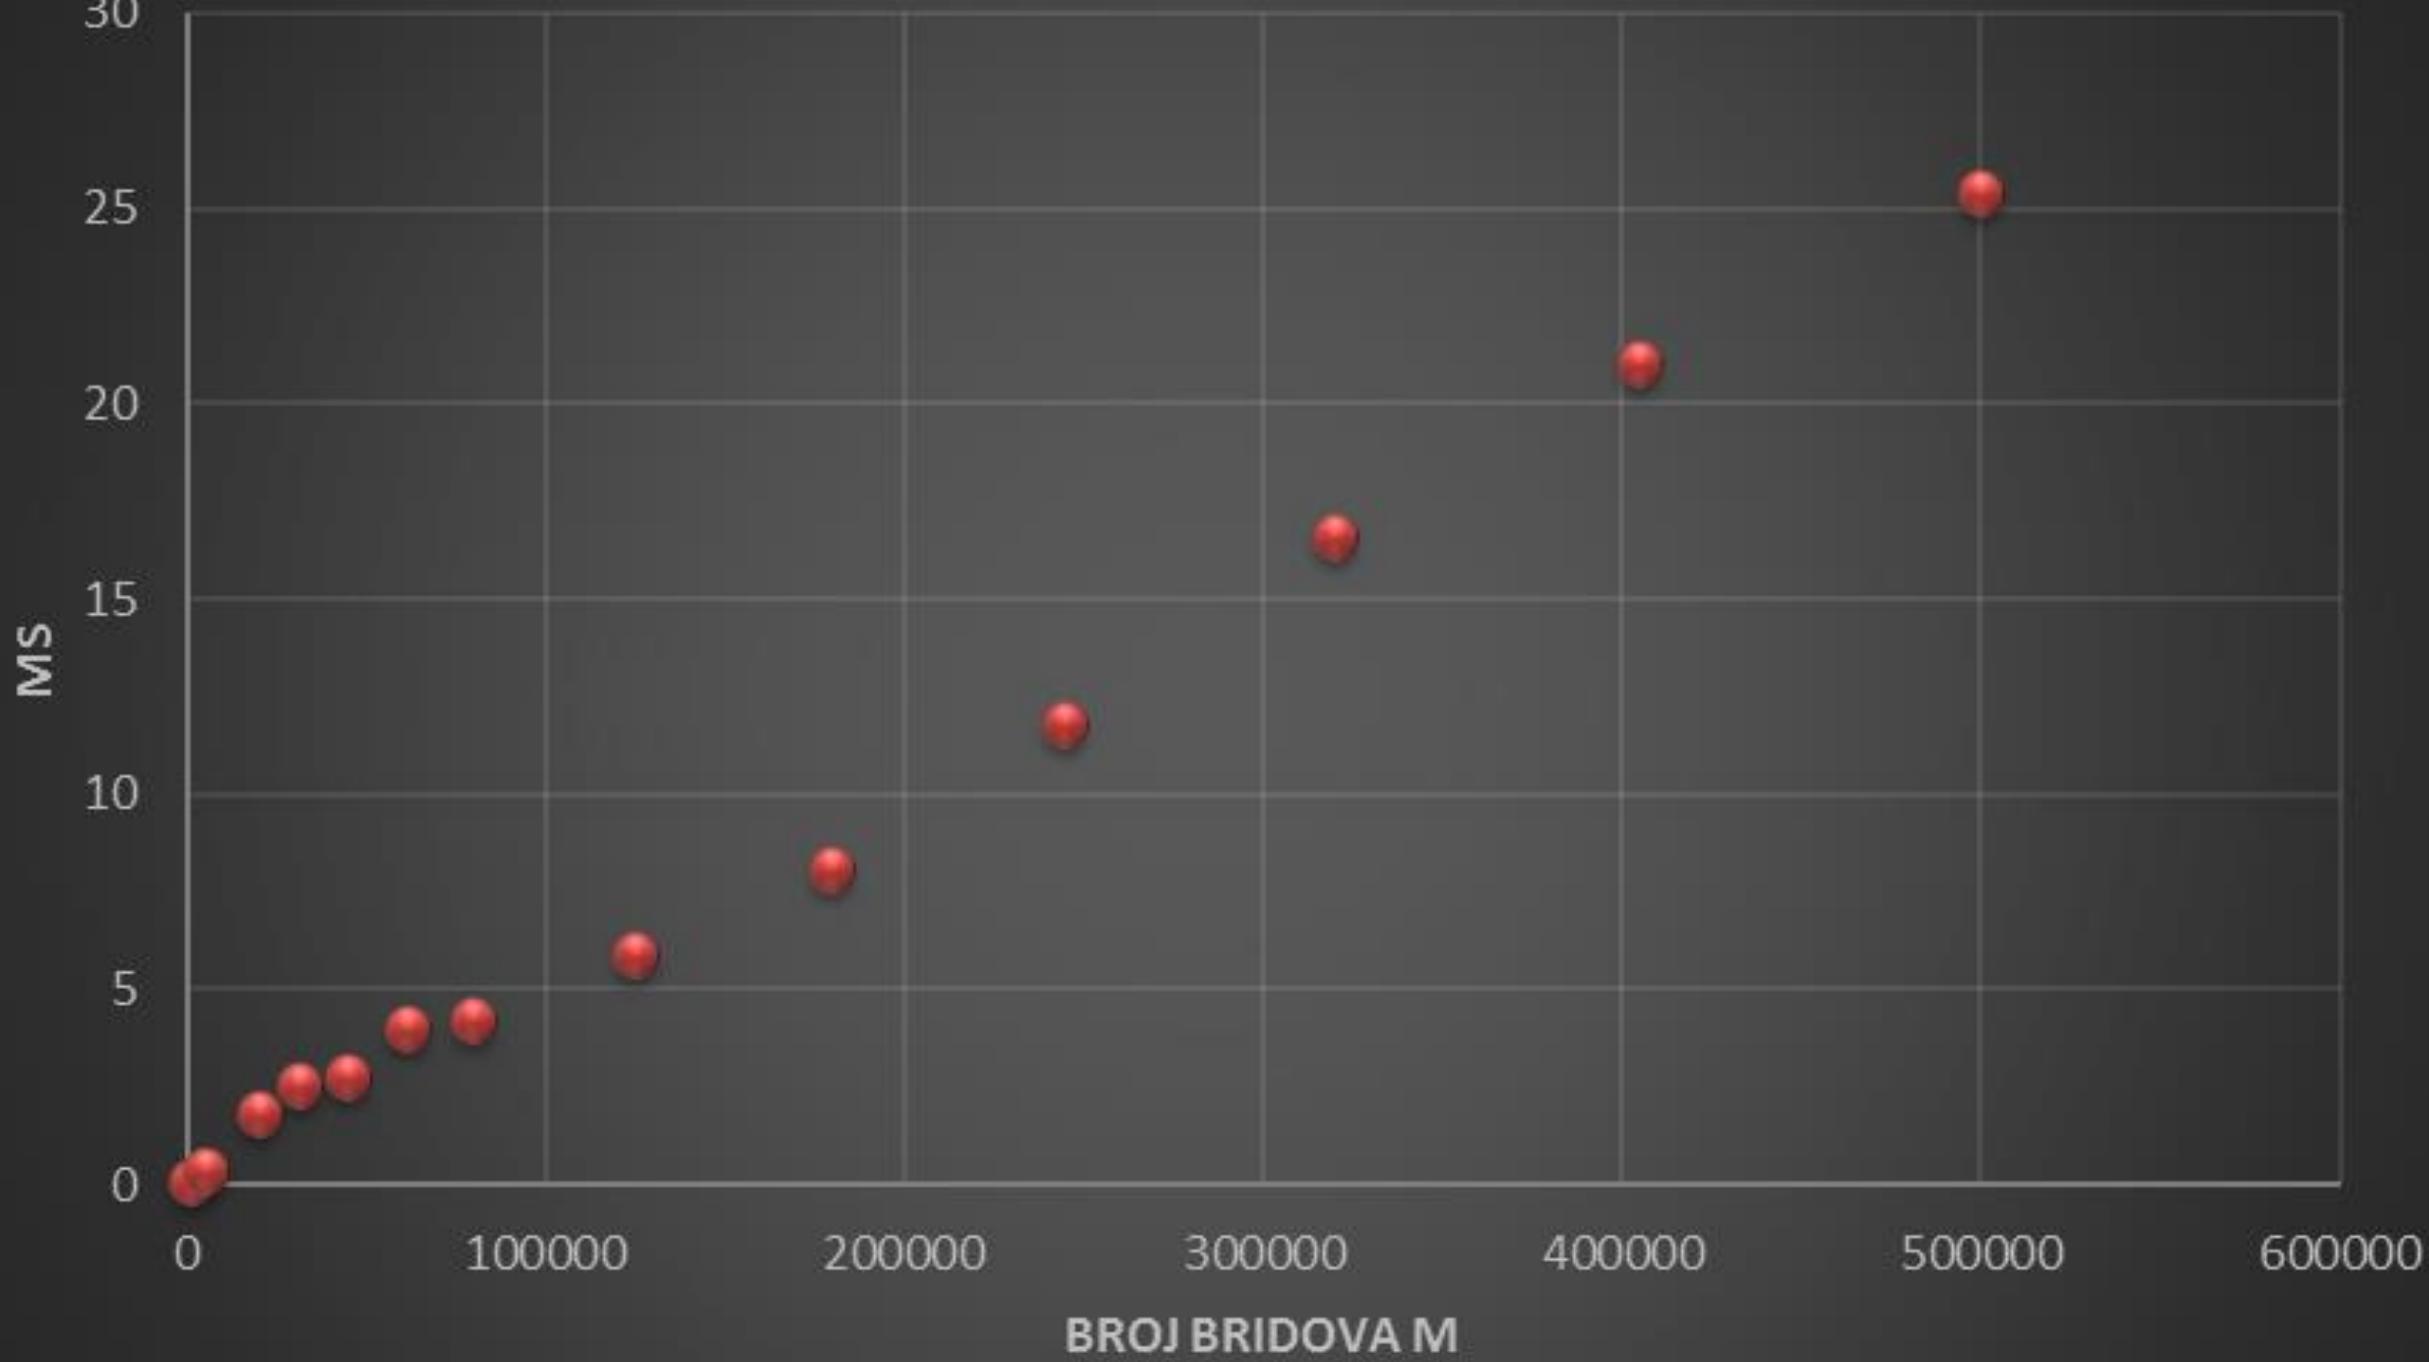
# OPIS TESTIRANJA

- Testiramo brzinu Kruskalovog algoritma u ovisnosti o broju vrhova i bridova grafa.
- Ispitujemo vrijeme trajanja Kruskalovog algoritma u milisekundama.
- Uzimamo 100 slučajno generiranih potpunih težinskih grafova s  $n$  vrhova.
  - Promatramo prosječno vrijeme izvršavanja.
  - $n$  biramo između 50 i 1000.

# TESTIRANJE

- Za naš početni problem k-grupiranja svi grafovi su potpuni, tj. broj bridova  $m$  je jednak  $\binom{n}{2}$ .
- Očekivana ovisnost o broju vrhova je  $n^2 \log n$ .
- Uzimamo  $k = \frac{n}{2}$ .





# LITERATURA

- P. J. Cameron, *Combinatorics: Topics, Techniques, Algorithms*, Cambridge University Press, Cambridge, 1994.
- A. Karpatne, V. Kumar, M. Steinbach, P.N. Tan, Cluster Analysis: Basic Concepts and Algorithms, dostupno na <https://www-users.cs.umn.edu/~kumar001/dmbook/ch8.pdf> (8.1.2019.)
- J. Kleinberg, E. Tardos, *Algorithm Design*, Pearson Education, Cornell University, 2006.