

1. Na danih podatkih (X) izvedi hierarhično gručenje in nariši dendrograme za naslednje vrste povezanosti (linkage):

- a. Enojna (single)
- b. Popolna (complete)
- c. Povprečna (average)

$$X = [1, 2, 4, 8, 9, 14]$$

REŠITEV:

- a) Izračunamo razdalje med vsemi pari točk in izberemo najmanjšo:

$$d(1,2)=1, d(1,4)=3, d(1,8)=7, \dots d(1,14)=13$$

$$d(2,4)=2, \dots d(2,14)=12$$

$$d(4,8)=4, \dots d(4,14)=10$$

$$d(8,9)=1, \dots d(8,14)=6$$

$$d(9,14)=5$$

V dendrogramu narišemo povezavi na višini 1.

V našem primeru sta dva para z isto minimalno razdaljo – vzamemo oba in ju združimo v gruči G1 in G2:

Izračunamo razdalje med novima gručama in preostalimi točkami:

$$d(G1,4)=\min(d(1,4),d(2,4))=2, \quad (\text{V dendrogramu narišemo povezavo na višini } 2)$$

$$d(G1,G2)=\min(d(1,8),d(2,8),d(1,9),d(2,9))=6,$$

$$d(G1,14)=\min(d(1,14),d(2,14))=12$$

$$d(G2,14)=5$$

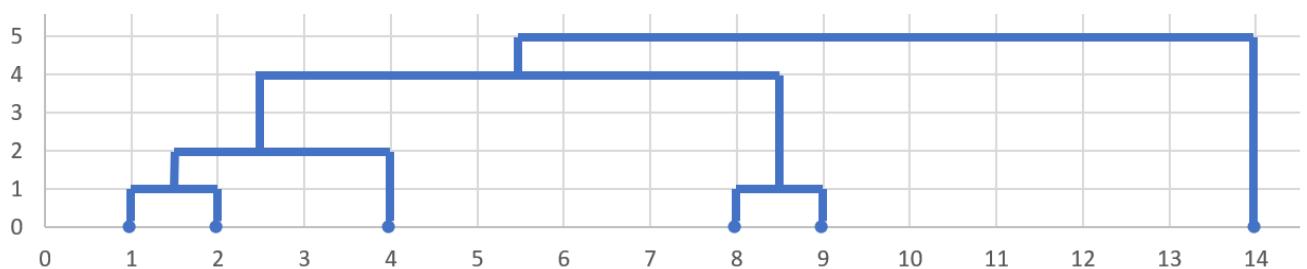
Gručo G1 povežemo s točko 4 v novo gručo G3 in izračunamo nove razdalje:

$$d(G3,G2)=\min(\dots)=d(4,8)=4 \quad (\text{kar je še vedno manjše od najmanjše naslednje razdalje, } d(G2,14)=5)$$

Zato v dendrogramu povežemo gruči G2 in G3 v novo gručo G4 na višini 4.

Preostane nam le še to, da povežemo gručo G4 s točko 14 – razdalja med njima je 5.

Dendrogram za enojno povezanost je torej:



- b) Popolna povezanost:

začetek je isti kot pri enojni povezanosti, do razlik pride šele v drugem koraku, ko računamo razdalje med gručo in točko ali med dvema gručama:

$$d(G1,4)=\max(d(1,4),d(2,4))=3, \quad (\text{V dendrogramu narišemo povezavo na višini } 3)$$

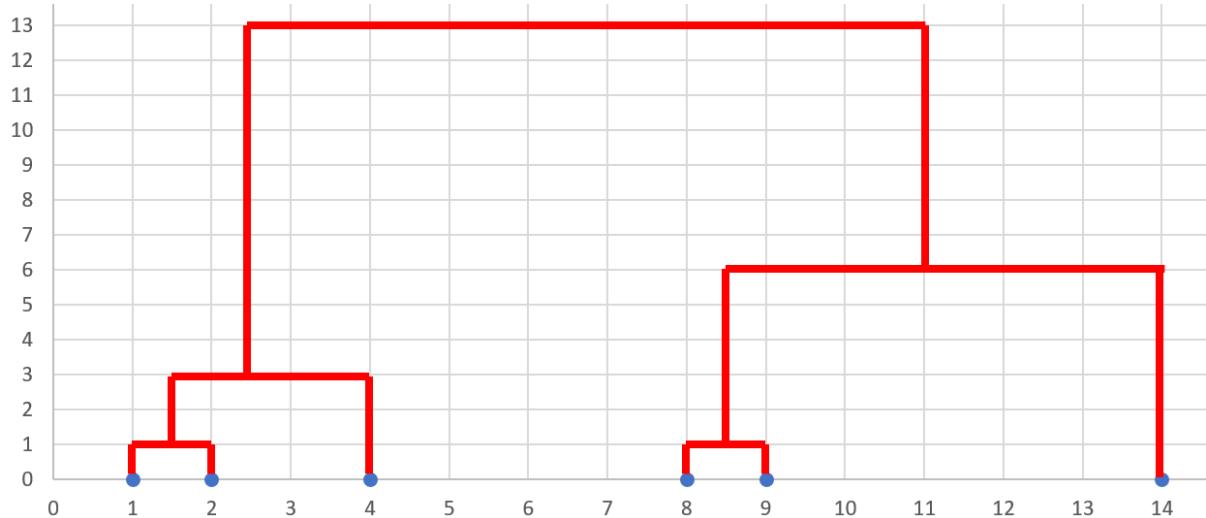
$$d(G2,14)=\max(d(8,14),d(9,14))=6$$

Naredimo torej novo gručo G3, ki povezuje G1 in 4. Izračunamo nove razdalje:

$$d(G3,G2)=\dots \text{najdaljša razdalja med točkami v G1 in gruči G2} \dots = d(1,9)=8$$

$$d(G2,14)=\max(d(8,14),d(9,14))=6$$

Na naslednjem koraku povežemo G2 in 14 v gručo G4. V zadnjem koraku nam preostane le še povezava med G3 in G4, na višini 13 (ker je max razdalja med dvema točkama iz teh grup enaka $d(1,14)=13$).

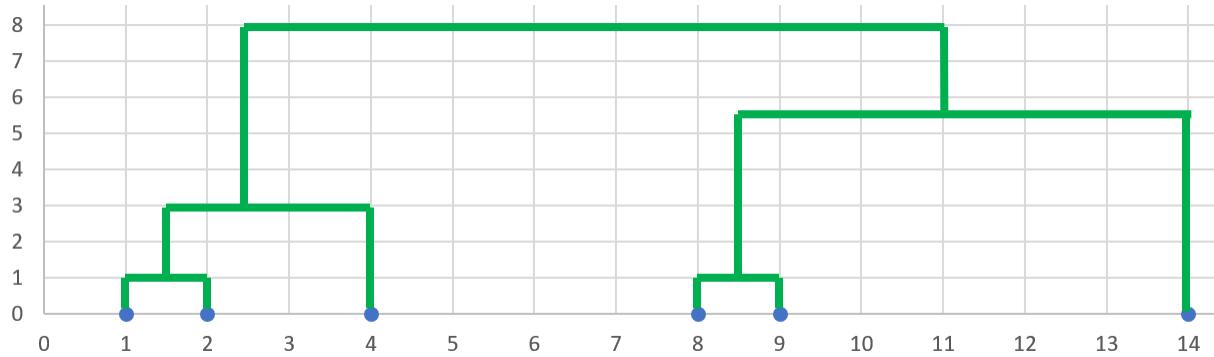


- c) Pri povprečni povezanosti je prvi korak spet isti kot prej, nato pa namesto min oz. max računamo povprečje vseh razdalj med dvema gručama oz. gručo in točko.

$$d(G_1, 4) = 2.5, \dots \text{ naredimo } G_3$$

$$d(G_2, 14) = 5.5 \dots$$

Dendrogram za povprečno povezanost:



2. Na danih podatkih simuliraj metodo k-voditeljev (k-Means) za k=3. Začetni centroidi naj bodo

$$C1 = 2, C2 = 5, C3 = 11$$

$$X = [1, 2, 4, 5, 8, 9, 11, 12, 15, 16, 17, 18]$$

REŠITEV

V tabeli so za vsako točko izračunane razdalje do vseh treh centroidov. Z barvo so označene minimalne razdalje v vsaki vrstici, ki kažejo tudi na pripadnost točke najbližjemu centroidu.

x	C1	C2	C3
1	2	5	11
2	1	4	10
4	0	3	9
5	2	1	7
8	3	0	6
9	6	3	3
11	7	4	2
12	9	6	0
15	10	7	1
16	13	10	4
17	14	11	5
18	15	12	6
1	16	13	7

Na novo izračunamo centroide:

$$C1 = (1+2)/2 = 1,5$$

$$C2 = (4+5+8)/3 = 4,5$$

$$C3 = (8+9+11+12+15+16+17+18)/7 = 13,25$$

... in ponavljamo postopek, dokler se pripadnost gručam ne ustali:

x	C1	C2	C3
1	1,5	4,5	13,25
2	0,5	3,5	12,25
4	0,5	2,5	11,25
5	2,5	0,5	9,25
8	3,5	0,5	8,25
9	6,5	3,5	5,25
11	7,5	4,5	4,25
12	9,5	6,5	2,25
15	11	7,5	1,25
16	14	10,5	1,75
17	15	11,5	2,75
18	16	12,5	3,75
1	17	13,5	4,75

x	C1	C2	C3
1	1,5	5,67	14
2	0,5	4,67	13
4	2,5	1,67	10
5	3,5	0,67	9
8	6,5	2,33	6
9	7,5	3,33	5
11	9,5	5,33	3
12	10,5	6,33	2
15	13,5	9,33	1
16	14,5	10,3	2
17	15,5	11,3	3
18	16,5	12,3	4

x	C1	C2	C3
1	1,5	6,5	14,8333
2	0,5	5,5	13,8333
4	2,5	2,5	10,8333
5	3,5	1,5	9,83333
8	6,5	1,5	6,83333
9	7,5	2,5	5,83333
11	9,5	4,5	3,83333
12	10,5	5,5	2,83333
15	13,5	8,5	0,16667
16	14,5	9,5	1,16667
17	15,5	10,5	2,16667
18	16,5	11,5	3,16667

Preverimo rezultat še s programom:

```
from sklearn.cluster import KMeans
import numpy as np

X = np.array([[1], [2], [4], [5], [8], [9], [11], [12], [15], [16], [17], [18]])
C = np.array([[2], [5], [11]], np.float64)

kmeans = KMeans(n_clusters=3, init=C).fit(X)
kmeans.cluster_centers_
```

Izpis centroidov se ujema z našim izračunom:

```
array([[ 1.5        ],
       [ 6.5        ],
       [14.83333333]])
```