


8. Sailkapen gainbegiratu gabea: Clustering Ariketak

- Demagun bi dimentsioko 5 kasuz osatutako datubasea dugula. Kasuak ez daude etiketatuta, eta beren arteko distantzia Euklidentarrak ezagunak dira.

Kasua	X	Y		$\mathbf{x}_1$	$\mathbf{x}_2$	$\mathbf{x}_3$	$\mathbf{x}_4$	$\mathbf{x}_5$
$\mathbf{x}_1$	1	1	$\mathbf{x}_1$	0	3.16	2.24	4.47	4.24
$\mathbf{x}_2$	2	4	$\mathbf{x}_2$		0	2.24	1.41	2.00
$\mathbf{x}_3$	3	2	$\mathbf{x}_3$			0	3.00	2.24
$\mathbf{x}_4$	3	5	$\mathbf{x}_4$				0	1.41
$\mathbf{x}_5$	4	4	$\mathbf{x}_5$					0

Datubasea

Distantzien matrizea



Erabil ezazu ***k*-means partiziozko clustering algoritmoa** honako kasuetan:

- Cluster kopurua $k = 2$ suposatuz. Hasierako haziak: $\mathbf{x}_1 \in Cl_1$ eta $\mathbf{x}_2 \in Cl_2$
- Cluster kopurua $k = 2$ suposatuz. Hasierako haziak: $\mathbf{x}_4 \in Cl_1$ eta $\mathbf{x}_5 \in Cl_2$
- $k = 3$ suposatuz. Hasierako haziak: $\mathbf{x}_2 \in Cl_1$, $\mathbf{x}_4 \in Cl_2$ eta $\mathbf{x}_5 \in Cl_3$

Erabil ezazu **behetik gorako clustering algoritmo hierarkikoa**, cluster arteko lotura hauetarako:

- Lotura distantzia minimoarekin (“single linkage”)
- Lotura distantzia maximoarekin (“complete linkage”)

Demagun clustering-erako bi algoritmo erabiliz honako bi partizioak lortu direla:


$$P_1 = \{Cl_1, Cl_2\} = \{\{\mathbf{x}_1\}, \{\mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_5\}\}$$

$$P_2 = \{Cl_1, Cl_2\} = \{\{\mathbf{x}_1, \mathbf{x}_3\}, \{\mathbf{x}_2, \mathbf{x}_4, \mathbf{x}_5\}\}$$

- Partizio bakoitzerako **Clusterren kohesioa** kalkula ezazu SSE (Sum of Squared Error) neurria erabiliz. Zeinek du kohesiorik altuena?

2. Demagun bi dimentsioko 8 kasuz osatutako datubasea dugula. Kasuak ez daude etiketatuta, eta beren arteko distantzia Euklidentarrak ezagunak dira.

Kasua	X_1	X_2		x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8
x_1	2	0	x_1	0	4.47	1.41	4.00	2.00	3.00	4.12	3.16
x_2	4	4	x_2		0	4.24	2.00	2.83	2.24	1.00	1.41
x_3	1	1	x_3			0	3.16	1.41	2.24	3.61	2.83
x_4	2	4	x_4				0	2.00	1.00	1.00	1.41
x_5	2	2	x_5					0	1.00	2.24	1.41
x_6	2	3	x_6						0	1.41	1.00
x_7	3	4	x_7							0	1.00
x_8	3	3	x_8								0



Erabil ezazu ***k*-means partiziozko clustering algoritmoa** honako kasuetan:

2.1 Cluster kopurua $k = 2$ suposatuz. Hasierako haziak: $x_1 \in Cl_1$ eta $x_2 \in Cl_2$

2.2 Cluster kopurua $k = 2$ suposatuz. Hasierako haziak: $x_2 \in Cl_1$ eta $x_7 \in Cl_2$

2.3 $k = 3$ suposatuz. Hasierako haziak: $x_2 \in Cl_1$, $x_4 \in Cl_2$ eta $x_7 \in Cl_3$

Erabil ezazu **behetik gorako clustering algoritmo hierarkikoa**, cluster arteko lotura hauetarako:

2.4 Lotura distantzia minimoarekin (“single linkage”)

2.5 Lotura distantzia maximoarekin (“complete linkage”)


Demagun clustering-erako bi algoritmo erabiliz honako bi partizioak lortu direla:

$$P_1 = \{Cl_1, Cl_2\} = \{\{x_1, x_3\}, \{x_2, x_4, x_5, x_6, x_7, x_8\}\}$$

$$P_2 = \{Cl_1, Cl_2\} = \{\{x_1, x_3, x_5\}, \{x_2, x_4, x_6, x_7, x_8\}\}$$

2.6 Partizio bakoitzerako **Clusterren kohesioa** kalkula ezazu SSE (Sum of Squared Error) neurria erabiliz. Zeinek du kohesiorik altuena?

3. Izan bedi 8 kasuz osatutako $D = \{1, 2, 3, 4, 5, 6, 7, 8\}$ datubasea. Indizedun clustering algoritmo hierarkiko bat aplikatu dugu, cluster arteko lotura desberdinetarako: distantzia minimoarekin (single linkage), distantzia maximoarekin (complete linkage), batazbesteko distantziarekin (average linkage), distantzia zentroidean (centroid linkage). Hauek dira lortutako lau dendrogramak:



Dendrograma bakoitzetik abiatuz,

3.1 Proposa ezazu, arrazoituz, datubasearen partiketa bat.

3.2 Cluster arteko loturak distantzia minimoa eta maximoa erabiliz lortutako bi dendrogrametarako (lehenengo biak) idatz ezazu dagokien ultrametrikien matrizea.

Oharra: Lau dendrogramak 2. ariketako datubaseari dagozkio. Ikus bertan kasuen arteko distantzia euklidestarrak, eta konparatu dendrogrametatik lortutako ultrametrikien matrizeekin.