

Ejemplos de análisis cluster

Objetivos:

- 1. Una aproximación a la terminología del análisis cluster o de conglomerados**
- 2. Uso de las funciones oportunas de R para realizar el análisis**
- 3. Interpretación de los resultados**

I. Ejemplo (datos ficticios en eje1.sav)

- 1. Datos**
- 2. Representación gráfica previa**
- 3. Exploración de la matriz de distancias entre los casos (distancia euclídea)**
- 4. Análisis cluster jerárquico: AC**
- 5. Dendrograma**
- 6. bannerplot:**

II. Ejemplo (datos reales en archivo ccaa1.sav)

- 1. Datos**
- 2. Análisis con las variables estandarizadas**
 - Tabla de agrupamiento**
 - Dendrograma**
- 3. Otras funciones usadas con hclust**
 - Función cutree()**
- 4. Análisis cluster con método kmeans**
 - 4.1. Kmeans indicando sólo el número de grupos**
 - 4.2. Representación gráfica de las Comunidades Autónomas en las 2 primeras componentes de Z, identificación de grupo y centroides.**
 - 4.3. Kmeans indicando las medias de los grupos**

Ejemplos de análisis cluster

Proponemos 2 ejemplos. Uno con datos ficticios, relativamente simple, con objeto de efectuar una primera aproximación metodológica a la técnica de A.C (análisis cluster), indicando los resultados usuales relativos a este tratamiento estadístico.

Otro ejemplo con datos reales, sobre las comunidades autónomas. Los datos, de acceso libre, se han obtenido de la Web (Ministerio de Trabajo y Asuntos Sociales).

I. Ejemplo (datos ficticios en eje1.sav)

Mediante este ejemplo simple con sólo dos variables (por tanto podría determinarse visualmente el agrupamiento) pretendemos mostrar el modo en que opera la técnica de A.C.

Tenemos 11 elementos o casos sobre los que se observan dos variables X e Y. Deseamos encontrar la mejor agrupación de los casos en función de sus valores en ambas variables.

1. Datos:

```
#Análisis cluster eje1  
require(foreign)  
a=read.spss("eje1.sav",use.value.labels = TRUE, to.data.frame = T)
```

```
>a
```

	CASO	X	Y
1	1	1	8
2	2	2	4
3	3	3	8
4	4	10	23
5	5	22	25
6	6	21	25
7	7	23	26
8	8	44	9
9	9	45	5
10	10	48	8
11	11	49	6


```
> d=a[,-1] #Dos columnas de datos con valores en X e Y
```

2. Representación gráfica previa:

El aspecto visual del gráfico parece indicar que hay 3 ó 4 grupos claramente diferenciados.

Realizaremos un análisis cluster para determinar cómo agrupa el método seleccionado estos 11 casos.

Diagrama de dispersión



3. Exploración de la matriz de distancias entre los casos (distancia euclídea)

La **matriz de distancias** expresa el distanciamiento entre pares de casos. La medida de distancia seleccionada es la distancia euclídea al cuadrado.

```
> dist(d)^2
```

	1	2	3	4	5	6	7	8	9	10
2	17									
3	4	17								
4	306	425	274							
5	730	841	650	148						
6	689	802	613	125	1					
7	808	925	724	178	2	5				
8	1850	1789	1682	1352	740	785	730			
9	1945	1850	1773	1549	929	976	925	17		
10	2209	2132	2025	1669	965	1018	949	17	18	
11	2308	2213	2120	1810	1090	1145	1076	34	17	5

4. Análisis cluster jerárquico: AC

Resultados:

Tabla de agrupamiento (merge)

Resultado con método “complete”:

```
> cj=hclust(dist(d), method = "complete")
> cj$merge
```

```
[, 1] [, 2]
[1, ] -5 -6
[2, ] -1 -3
[3, ] -7 1
[4, ] -10 -11
[5, ] -2 2
[6, ] -8 -9
[7, ] 4 6
[8, ] -4 3
[9, ] 5 8
[10, ] 7 9
```

Según la tabla anterior, en el paso 1, se unen los cluster formados por una sola observación 5 y 6. Los signos negativos indican que cuando se unen están formados

por una sola observación cada uno. En paso 2, se unen los cluster 1 y 3. Cuando se une el cluster 7 (formado por una sola observación) lo hace con el formado por otro cluster anterior que se formó en el paso 1 (es decir, al formado por 5 y 6) etc. En el paso 5, el elemento 2 se une por primera vez a otro cluster formado en el paso 2 (es decir, al constituido por los elementos 1 y 3). En el paso 7: el cluster formado en el paso 4 se une al formado en el paso 6. En el paso 8: por primera vez el elemento 4 se une al cluster formado en el paso 3.

Resultado con método “average”:


```
> cj=hclust(dist(d)^2, method = "average")
> cj$height #valor de medida proximidad a la que se van formando los cluster
[1] 1.0000 3.5000 4.0000 5.0000 17.0000 17.0000 21.5000
[8] 150.3333 648.9167 1485.8571

> cj$merge
[,1] [,2]
[1,] -5 -6
[2,] -7 1
[3,] -1 -3
[4,] -10 -11
[5,] -2 3
[6,] -8 -9
[7,] 4 6
[8,] -4 2
[9,] 5 8
[10,] 7 9
```

5. Dendrograma:

El dendrograma es una valiosa herramienta visual que puede ayudar a decidir el número de grupos que podrían representar mejor la estructura de los datos teniendo en cuenta la forma en que se van anidando los cluster y la medida de similitud a la cual lo hacen. Cortando el gráfico con un segmento perpendicular a las ramas se obtiene una partición con un número de grupos igual a las ramas “cortadas”..


El número de cluster o clases en que deseamos agrupar los datos nos llevará “cortar” el dendrograma del ejemplo verticalmente y ver a qué nivel de similitud se da dicho agrupamiento. En el ejemplo puede apreciarse un salto importante en la longitud de las líneas verticales que definen los grupos en 3. Cuando se observa en la escala vertical un amplio rango sin existencia de agrupamiento puede ser un indicio de que los cluster se encuentran separados a esos niveles de similaridad.



```
dist(d)^2
hclust (*, "average")
```

6. bannerplot:

```
require(cluster)
bannerplot(agnes(d), main = "Bannerplot")
```



II. Ejemplo (datos reales en archivo cca1.sav)

1. Datos

Se ha observado el conjunto de variables siguientes sobre las comunidades autónomas.

CA	Comunidad autónoma
TTACT_AC	trabajadores por centro de trabajo abierto (año 1992)
CCT23_EC	tasa de convenios colectivos por efectivos laborales
ECL28_EC	efectivo laboral mujer a total
PEN26	Importe medio pensiones
EPA30	tasa de paro
EPA28	tasa de actividad
ECL41	Jornada efectiva media trab Construcción
ECL42	Jornada efectiva media trab. Servicios
ECL29_EC	Tasa contratos indefinidos

Se desea encontrar un agrupamiento de las comunidades autónomas que refleje posibles similitudes entre subconjuntos de ellas.

Se leerá directamente el archivo creado por SPSS. Para ello se usa el package **foreign**

```
require(foreign)
```

```
a=read.spss("aacc1.sav",use.value.labels = TRUE, to.data.frame = T)
```

Etiquete los casos mediante la variable Comunidad autónoma y elimine del análisis la última fila que presenta casi todos los valores faltantes:

```
> require(foreign)
> a=read.spss("aacc1.sav",use.value.labels = TRUE, to.data.frame = T)
> a
```

	CA	TTACT_AC	CCT23_EC	ECL28_EC	PEN26	EPA30	EPA28	ECL41	ECL42
1	Andalucía	3.614452	0.9464471	0.2766652	336.30	34.6	49.1	1788.3	1633.5
2	Aragón	2.668203	0.9934498	0.2560044	362.91	18.3	50.0	1769.0	1693.2
3	Asturias	2.996850	0.8620690	0.2193103	429.00	22.0	45.5	1771.1	1667.8
4	Baleares	2.281031	0.6651885	0.3458980	321.95	17.8	55.8	1752.3	1719.3
5	Canarias	2.177279	0.8086022	0.2993548	344.61	26.5	53.6	1779.4	1716.7
6	Cantabria	2.979269	1.4835949	0.2453638	364.37	23.4	48.1	1787.7	1659.7
7	Castilla-	3.067719	0.8758732	0.2912413	335.18	19.7	46.5	1719.8	1662.7
8	Castilla y	3.145628	1.3152610	0.2590361	346.83	21.4	47.1	1783.2	1634.1
9	Cataluña	3.656853	0.4121212	0.3311515	362.20	21.2	54.3	1731.0	1668.9
10	Comunidad	3.278427	0.6621813	0.2811615	326.86	24.6	52.9	1764.0	1668.4
11	Extremadura	2.949342	0.9617918	0.2595520	319.30	31.6	47.2	1833.1	1657.6
12	Galicia	3.016105	1.0200724	0.2757486	304.16	19.9	51.3	1808.5	1682.8
13	Madrid	4.957789	0.3229568	0.3286086	415.14	20.6	52.2	1743.1	1671.5
14	Murcia	3.464200	0.7412791	0.2979651	324.05	25.5	52.2	1724.9	1640.5
15	Navarra	3.780303	0.6811731	0.2942289	380.36	14.6	49.7	1739.6	1594.4
16	País Vasco	3.893989	0.9929078	0.2765957	435.77	24.4	52.2	1731.4	1608.6
17	La Rioja	2.198276	1.2468828	0.2768080	341.83	17.0	47.2	1775.4	1668.8
18	Ceuta y	2.863830	NA	NA	390.35	28.9	49.2	NA	NA
	ECL29_EC								
1	0.6367008								
2	0.7232533								
3	0.7448276								
4	0.6644494								
5	0.5716129								
6	0.7047076								
7	0.5765717								
8	0.6977912								
9	0.7125657								
10	0.6322592								
11	0.5704875								
12	0.6755512								
13	0.7218086								
14	0.6664244								
15	0.7029328								
16	0.7815057								
17	0.6982544								

```
18      NA
```

```
X=a[-18,-1]
```

Transformación de valores:

Use función scale para estandarizar las variables, dada la diversidad en la escala usada en cada una de ellas.

```
Z=scale(X[,1:9])
```

```
row.names(Z)=as.character(a[-18,1])  
Z
```

2. Análisis con las variables estandarizadas:

```
> cj=hclust(dist(Z)^2, method = "average")
```

Tabla de agrupamiento

```
> cj$merge  
 [,1] [,2]  
[1,] -6 -8  
[2,] -10 -14  
[3,] -2 -17  
[4,] 1 3  
[5,] -1 -11  
[6,] -9 -13  
[7,] -12 4  
[8,] -7 2  
[9,] -4 -5  
[10,] -15 -16  
[11,] -3 7  
[12,] 8 9  
[13,] 6 10  
[14,] 5 11  
[15,] 12 14  
[16,] 13 15  
  
> cj$height #valor de medida proximidad a la que se van formando los cluster  
[1] 1.653461 3.107534 3.546699 5.437224 5.902104 6.108125 6.955964  
[8] 8.499887 9.186171 9.706844 12.227541 14.028419 14.177907 16.740706  
[15] 17.976822 23.466064
```


```
> print(cj)
```

```
Call:  
hclust(d = dist(Z)^2, method = "average")  
Cluster method : average  
Distance : euclidean  
Number of objects: 17
```

Dendrograma

```
> plot(cj,main="Dendograma",labels=row.names(Z),hang=-1)
```

Dendograma



Según el dendrograma anterior, si decidimos establecer 4 cluster, estarán formados por los siguientes casos:

Cluster: Cantabria, Castilla y León, Aragón, La Rioja y Galicia

Cluster: Andalucía y Extremadura

Cluster: Comunidad Valenciana, Murcia, Castilla-La Mancha, Baleares, Canarias

Cluster: Cataluña, Madrid, Navarra, País Vasco.

3. Otras funciones usadas con hclust

Realice 4 grupos y añada esta variable, que identifica el grupo, a Z

Función cutree()

```
cutree(objeto, k = NULL, h = NULL)
```

Puede usar el número de grupos a efectuar o bien un valor de la medida de distanciamiento (h) para agrupar.

R permite guardar en una variable la asignación de cada caso a un grupo o cluster:

```
> g=cutree(cj,k=4)
> cbind(Z,g)

          TTACT_AC    CCT23_EC    ECL28_EC    PEN26    EPA30
Andalucía  0. 61892344  0. 21586980 -0. 20378143 -0. 5043529  2. 3638717
Aragón     -0. 74121206  0. 37300021 -0. 84636721  0. 1793164 -0. 8298331
Asturias   -0. 26881599 -0. 06620725 -1. 98761235  1. 8773137 -0. 1048817
Baleares   -1. 29773088 -0. 72438084  1. 94947452 -0. 8730359 -0. 9277995
Canarias   -1. 44686468 -0. 24494738  0. 50190461 -0. 2908508  0. 7768160
Cantabria -0. 29408648  0. 01156042 -1. 17730760  0. 2168270  0. 1694243
Castilla-  -0. 16694844 -0. 02005960  0. 24955907 -0. 5331282 -0. 5555271
Castilla y -0. 05496253  1. 44881868 -0. 75207387 -0. 2338141 -0. 2224414
Cataluña   0. 67987025 -1. 57038737  1. 49083417  0. 1610750 -0. 2616279
Comunidad  0. 13592304 -0. 73443383 -0. 06393933 -0. 7468873  0. 4045436
Extremadura -0. 33710324  0. 26716735 -0. 73602860 -0. 9411203  1. 7760733
Galicia    -0. 24113892  0. 46199988 -0. 23228865 -1. 3301001 -0. 5163406
Madrid     2. 54983268 -1. 86846478  1. 41174509  1. 5212198 -0. 3791876
Murcia    0. 40295120 -0. 47000916  0. 45868193 -0. 8190823  0. 5808832
Navarra    0. 85731741 -0. 67094395  0. 34248094  0. 6276452 -1. 5547845
País Vasco 1. 02072874  0. 37118836 -0. 20594109  2. 0512498  0. 3653571
La Rioja   -1. 41668353  1. 22022946 -0. 19934021 -0. 3622751 -1. 0845457
          EPA28          ECL41          ECL42          ECL29_EC  g
Andalucía -0. 38885757  0. 75439325 -0. 85349573 -0. 633719729 1
Aragón     -0. 09432684  0. 13451740  0. 95488176  0. 783829528 2
Asturias   -1. 56698051  0. 20196503  0. 18548832  1. 137171749 2
Baleares   1. 80376013 -0. 40185185  1. 74547895 -0. 179255769 3
Canarias   1. 08379611  0. 46854377  1. 66672214 -1. 699723508 3
Cantabria -0. 71611395  0. 73512250 -0. 05986943  0. 480089403 2
Castilla-  -1. 23972414 -1. 44568424  0. 03100381 -1. 618508175 3
Castilla y -1. 04337032  0. 59059186 -0. 83532108  0. 366813262 2
Cataluña   1. 31287557 -1. 08596354  0. 21880851  0. 608788626 4
Comunidad  0. 85471664 -0. 02607219  0. 20366297 -0. 706463537 3
Extremadura -1. 01064468  2. 19327604 -0. 12348070 -1. 718155535 1
Galicia    0. 33110645  1. 40317522  0. 63985452  0. 002568502 2
Madrid     0. 62563718 -0. 69733671  0. 29756532  0. 760168081 4
Murcia    0. 62563718 -1. 28188285 -0. 64145817 -0. 146908621 3
Navarra    -0. 19250375 -0. 80974943 -2. 03787696  0. 451022997 4
País Vasco 0. 62563718 -1. 07311637 -1. 60774363  1. 737883222 4
La Rioja   -1. 01064468  0. 34007209  0. 21577940  0. 374399503 2

> table(g)
g
1 2 3 4
2 6 5 4
```

4. Análisis cluster con método kmeans

Proporciona las medias de los cluster, la suma de cuadrados dentro de los cluster, los tamaños de los cluster y los elementos que forman cada cluster.

4.1. Kmeans indicando sólo el número de grupos

Partiremos de un agrupamiento formado por 4 cluster

```
> kmeans(Z,4)

K-means clustering with 4 clusters of sizes 7, 4, 4, 2

Cluster means:
          TTACT_AC    CCT23_EC    ECL28_EC    PEN26    EPA30    EPA28
1  -0. 73923650  0. 04734399  0. 1941433 -0. 5652801 -0. 3903838  0. 2469548
2  -0. 01680720  0. 98585406 -0. 7172979 -0. 3656151  1. 0217320 -0. 7897466
3  1. 12249288 -1. 14495131  0. 9259355  0. 3727144 -0. 4036792  0. 5929115
4  0. 37595637  0. 15249056 -1. 0967767  1. 9642817  0. 1302377 -0. 4706717
          ECL41          ECL42          ECL29_EC
1  0. 0675286  0. 7796262 -0. 4347362
2  1. 0683459 -0. 4680417 -0. 3762431
3  -0. 9687331 -0. 5407403  0. 4182678
4  -0. 4355757 -0. 7111277  1. 4375275
```

```

Clustering vector:
Andalucía          Aragón        Asturias      Baleares     Canarias      Cantabria
2                  1             4             1             1             2
Castilla-          Castilla y    Cataluña      Comunidad   Extremadura  Galicia
1                  2             3             1             2             1
Madrid            Murcia       Navarra       País Vasco  La Rioja
3                  3             3             4             1

```

```

Within cluster sum of squares by cluster:
[1] 35.016891 14.493410 15.837275 7.644956

```

```

Available components:
[1] "cluster"  "centers"  "within"  "size"
>

```

4.2. Representación gráfica de las 2 primeras componentes de Z

Usaremos ahora las dos primeras componentes principales de las variables del data frame Z para construir los 4 grupos mediante el método kmeans.

Previo análisis de componentes principales. Resume las 9 variables en las 2 que capturan la máxima variabilidad del total.

```
>acp=princomp(Z)
```

Tomamos las puntuaciones en las componentes primeras para cada Comunidad Autónoma

```
>comp=predict(acp)[,1:2]
```

Análisis cluster con las 2 componentes principales


```
>km2=kmeans(comp,4)
```

Representación gráfica de las Comunidades según las puntuaciones en las componentes y el grupo al que se han asignado. Representación de los centroides (medias de los grupos en las componentes)

```

>plot(comp,col=km2$cluster) #cada cluster de un color
>points(km2$centers, col = 1:4, pch = 8, cex=2) #medias de los cluster en las componentes
>text(comp[,1],comp[,2],labels=rownames(Z),col=km2$cluster) #etiquetas de nombres Comunidades

```



4.3. Kmeans indicando las medias de los grupos

Utilizaremos el agrupamiento jerárquico realizado previamente tomando 4 grupos

#Los grupos son resultado del análisis jerarquico derivado de hclust

`g=cutree(cj,k=4)` #asignación de los elementos a cada grupo

```
> g
Andalucía 1     Aragón 2     Asturias 2     Baleares 3     Canarias 3     Cantabria 2
Castilla-  1     Castilla y 2     Cataluña 4     Comunidad 3     Extremadura 1     Galicia 2
Madrid    3     Murcia   3     Navarra   4     País Vasco 4     La Rioja  2
          4
```

Cálculo de medias por grupo con la función tapply:

```
> inicial=tapply(Z,list(rep(g,ncol(Z)),col(Z)),mean) #Calculo de medias por grupo
> inicial
      1        2        3        4        5        6
1  0. 1409101  0. 2415186 -0. 4699050 -0. 72273659  2. 06997252 -0. 6997511
2 -0. 5028166  0. 9082336 -0. 8658316  0. 05787797 -0. 43143637 -0. 6833883
3 -0. 4745340 -0. 4387662  0. 6191362 -0. 65259690  0. 05578322  0. 6256372
4  1. 2769373 -0. 9346519  0. 7597798  1. 09029746 -0. 45756074  0. 5929115
      7        8        9
1  1. 4738346 -0. 4884882 -1. 1759376
2  0. 5675740  0. 1834689  0. 5241453
3 -0. 5373895  0. 6010819 -0. 8701719
4 -0. 9165415 -0. 7823117  0. 8894657
```

Análisis cluster tomando como agrupamiento inicial el derivado previamente con hclust

`> km3=kmeans(Z,inicial)`

> km3

K-means clustering with 4 clusters of sizes 2, 6, 5, 4

Cluster means:

	TTACT_AC	CCT23_EC	ECL28_EC	PEN26	EPA30	EPA28
1	0.1409101	0.2415186	-0.4699050	-0.72273659	2.06997252	-0.6997511
2	-0.5028166	0.9082336	-0.8658316	0.05787797	-0.43143637	-0.6833883
3	-0.4745340	-0.4387662	0.6191362	-0.65259690	0.05578322	0.6256372
4	1.2769373	-0.9346519	0.7597798	1.09029746	-0.45756074	0.5929115
	ECL41	ECL42	ECL29_EC			
1	1.4738346	-0.4884882	-1.1759376			
2	0.5675740	0.1834689	0.5241453			
3	-0.5373895	0.6010819	-0.8701719			
4	-0.9165415	-0.7823117	0.8894657			

Clustering vector:

Andalucía	Aragón	Asturias	Baleares	Canarias	Cantabria
1	2	2	3	3	2
Castilla-La Mancha	Castilla y León	Cataluña	Comunidad de Madrid	Extremadura	Galicia
3	2	4	3	1	2
Madrid	Murcia	Navarra	País Vasco	La Rioja	
4	3	4	4	2	

Within cluster sum of squares by cluster:

[1] 2.951052 19.318436 22.692799 18.131649

Available components:

[1] "cluster" "centers" "wthi nss" "size"

En este caso no se ha producido ninguna modificación, pero en general, los agrupamientos diferirán de un método a otro.