

1-Práctica de Análisis BIPLot en R

Consideremos los datos de la matriz $X = \begin{pmatrix} -2 & -2 & -1 \\ 0 & 1 & 0 \\ 2 & 2 & 2 \\ 0 & -1 & -1 \end{pmatrix}$ recogida en la siguiente representación gráfica [Biplot](#). Vamos

a calcular las coordenadas de las filas y columnas F y G, en cada uno de los 3 tipos de Biplot (SQ, JK, GH), así como la representación gráfica Biplot en R, por último calcularemos la estimación de la matriz X obtenida a través de esta técnica.

Pasos a realizar en la práctica:

1. Crea el fichero de texto biplot1.txt con los datos de la matriz X

```
> X <- read.table("biplot1.txt")
> X
  v1 v2 v3
1 -2 -2 -1
2  0  1  0
3  2  2  2
4  0 -1 -1
```

2. Realiza el análisis de Componentes principales sobre X. Como esta matriz está centrada, las desviaciones típicas de la función prcomp, es decir los valores singulares de $X'X$, coinciden con las raíces cuadradas de los autovalores de la DVS de la matriz de covarianzas, es decir $2.7253 = \sqrt{7.4273}$. Si realizamos un ACP no centrado, este resultado no se daría.

```
> X_pca <- prcomp(X)
> X_pca
Standard deviations:
[1] 2.7253091 0.5773503 0.4892411 valores singulares de X'X
```

```
Rotation:
      PC1      PC2      PC3
v1 0.5735637 0.8164966 -0.06601555
v2 0.6544159 -0.4082483 0.63645361
v3 0.4927115 -0.4082483 -0.76848471
```

```
> summary(X_pca)
Importance of components:
      PC1      PC2      PC3
Standard deviation 2.7253 0.57735 0.48924
Proportion of Variance 0.9284 0.04167 0.02992
Cumulative Proportion 0.9284 0.97008 1.00000
```

3. Comprobemos estos resultados:

En el Análisis de Componentes Principales $X'X$ = matriz de covarianzas siendo $x_{ij} = \frac{r_{ij} - \bar{r}_j}{\sqrt{n-1}}$ ya que la función prcomp, trabaja con n-1, como la matriz de partida X está centrada, la única transformación que hay que hacer es dividir por raíz de n-1

```
> cov(X)=X'X
      v1      v2      v3
v1 2.666667 2.666667 2.000000
v2 2.666667 3.333333 2.333333
v3 2.000000 2.333333 2.000000
```

Veamos si a través de la anterior transformación llegamos a la matriz de covarianzas

```
> n <- 4
> X1 <- 1/sqrt(n-1)*(X)
```

```

      V1      V2      V3
1 -1.154701 -1.1547005 -0.5773503
2  0.000000  0.5773503  0.0000000
3  1.154701  1.1547005  1.1547005
4  0.000000 -0.5773503 -0.5773503
> X1 <- as.matrix(X1)
> (t(X1)%*%X1)
      V1      V2      V3
V1 2.666667 2.666667 2.000000
V2 2.666667 3.333333 2.333333
V3 2.000000 2.333333 2.000000

```

Efectivamente hemos llegado a la matriz de covarianzas

```

svd(cov(X))
$d
[1] 7.4273098 0.3333333 0.2393569 autovalores de X'X= cuadrado de los valores
singulares

$u
      [,1]      [,2]      [,3]
[1,] -0.5735637  0.8164966  0.06601555
[2,] -0.6544159 -0.4082483 -0.63645361
[3,] -0.4927115 -0.4082483  0.76848471

$v
      [,1]      [,2]      [,3]
[1,] -0.5735637  0.8164966  0.06601555
[2,] -0.6544159 -0.4082483 -0.63645361
[3,] -0.4927115 -0.4082483  0.76848471

```

En el Análisis de Componentes Principales normalizado $X'X$ =matriz de correlaciones donde $x_{ij} = \frac{r_{ij} - \bar{r}_j}{s_j \sqrt{n-1}}$

```

X_pca <- prcomp(X, scale=TRUE)
> X_pca
Standard deviations:
[1] 1.6661917 0.3668835 0.2986663 valores singulares de X'X

```

```

Rotation:
      PC1      PC2      PC3
V1 0.5739511 0.75162701 -0.3250185
V2 0.5820758 -0.09528683 0.8075322
V3 0.5759930 -0.65266934 -0.4921939

```

```

> summary(X_pca)
Importance of components:
      PC1      PC2      PC3
Standard deviation 1.6662 0.36688 0.29867
Proportion of Variance 0.9254 0.04487 0.02973
Cumulative Proportion 0.9254 0.97027 1.00000

```

```

> cor(X)
      V1      V2      V3
V1 1.0000000 0.8944272 0.8660254
V2 0.8944272 1.0000000 0.9036961
V3 0.8660254 0.9036961 1.0000000

```

```

> svd(cor(X))
$d
[1] 2.77619493 0.13460353 0.08920154 autovalores de X'X= cuadrado de los valores
singulares

```

```

$u
      [,1]      [,2]      [,3]
[1,] -0.5739511  0.75162701  0.3250185
[2,] -0.5820758 -0.09528683 -0.8075322
[3,] -0.5759930 -0.65266934  0.4921939

```

```

$v
      [,1]      [,2]      [,3]
[1,] -0.5739511  0.75162701  0.3250185

```

```
[2,] -0.5820758 -0.09528683 -0.8075322
[3,] -0.5759930 -0.65266934  0.4921939
```


Comprobemos los resultados, realizando la transformación paso a paso

```
X <- as.matrix(X)
> X
      V1 V2 V3
[1,] -2 -2 -1
[2,]  0  1  0
[3,]  2  2  2
[4,]  0 -1 -1
> n <- 4
> TX <- matrix(c((1/sqrt(cov(X)[1,1]))/sqrt(n-1),0,0,0,(1/sqrt(cov(X)[2,2]))/sqrt(n-1),0,0,0,(1/sqrt(cov(X)[3,3]))/sqrt(n-1)),ncol=3)
> TX
      [,1] [,2] [,3]
[1,] 0.3535534 0.0000000 0.0000000
[2,] 0.0000000 0.3162278 0.0000000
[3,] 0.0000000 0.0000000 0.4082483
> X1N <- X%*%TX
> X1N
      [,1] [,2] [,3]
[1,] -0.7071068 -0.6324555 -0.4082483
[2,]  0.0000000  0.3162278  0.0000000
[3,]  0.7071068  0.6324555  0.8164966
[4,]  0.0000000 -0.3162278 -0.4082483
> t(X1N)%*%X1N
      [,1] [,2] [,3]
[1,] 1.0000000 0.8944272 0.8660254
[2,] 0.8944272 1.0000000 0.9036961
[3,] 0.8660254 0.9036961 1.0000000
```

Efectivamente obtenemos la matriz de correlaciones

- Realiza la representación gráfica Biplot. Observa la posición de las 3 variables (columnas), representadas por vectores y de los 4 observaciones (filas) representadas por puntos

```
> biplot(X_pca)
```



- Vamos a realizar los cálculos para cada uno de los 3 tipos BIPLLOT, comenzamos calculando la (SVD) de la matriz X, (descomposición en valores singulares de X)

```
> svd(X)
```

```
$dx
[1] 4.7203739 1.0000000 0.8473905

$u
      [,1]      [,2]      [,3]
[1,] -0.6246689 -4.082483e-01 -0.4394567
[2,]  0.1386365 -4.082483e-01  0.7510747
[3,]  0.7290486  1.273997e-14 -0.4674271
[4,] -0.2430162  8.164966e-01  0.1558090

$v
      [,1]      [,2]      [,3]
[1,] 0.5735637  0.8164966 -0.06601555
[2,] 0.6544159 -0.4082483  0.63645361
[3,] 0.4927115 -0.4082483 -0.76848471
```

6. Vamos a comparar estos resultados de la DVS de X con los de la DVS de $X'X$, ($XX1$), y XX' , ($XX2$)

```
> X <- as.matrix(X)
> XX1 <- t(X)%*%X
> XX1
      v1 v2 v3
v1  8  8  6
v2  8 10  7
v3  6  7  6
> XX2 <- X%*%t(X)
> XX2
      [,1] [,2] [,3] [,4]
[1,]  9   -2  -10   3
[2,]  -2    1    2  -1
[3,] -10    2   12  -4
[4,]   3   -1   -4   2
> svd(XX1)
$d
[1] 22.2819293 1.0000000 0.7180707

$u
      [,1]      [,2]      [,3]
[1,] -0.5735637  0.8164966  0.06601555
[2,] -0.6544159 -0.4082483 -0.63645361
[3,] -0.4927115 -0.4082483  0.76848471

$v
      [,1]      [,2]      [,3]
[1,] -0.5735637  0.8164966  0.06601555
[2,] -0.6544159 -0.4082483 -0.63645361
[3,] -0.4927115 -0.4082483  0.76848471

> svd(XX2)
$d
[1] 2.228193e+01 1.000000e+00 7.180707e-01 6.222156e-16

$u
      [,1]      [,2]      [,3] [,4]
[1,] -0.6246689  4.082483e-01  0.4394567  0.5
[2,]  0.1386365  4.082483e-01 -0.7510747  0.5
[3,]  0.7290486 -5.477660e-16  0.4674271  0.5
[4,] -0.2430162 -8.164966e-01 -0.1558090  0.5

$v
      [,1]      [,2]      [,3] [,4]
[1,] -0.6246689  4.082483e-01  0.4394567 -0.5
[2,]  0.1386365  4.082483e-01 -0.7510747 -0.5
[3,]  0.7290486 -5.595025e-16  0.4674271 -0.5
[4,] -0.2430162 -8.164966e-01 -0.1558090 -0.5
```

Se observa la relación existente entre las DVS de $X'X$ y XX' , (que coinciden con las autodescomposiciones de $X'X$ y XX') y la DVS de X, en el 1º caso los vectores singulares a izquierda y derecha son iguales, vectores U, para $X'X$ y vectores V para XX' , (aquí los nombres u y v están intercambiados en relación a la teoría), y también se observa que los valores singulares son las raíces cuadradas de los autovalores, ya que en la DVS, se obtienen valores singulares y en las autodescomposiciones, autovalores.

También se puede comprobar que las componentes principales del análisis realizado en el apartado 2, coinciden con los vectores U de $X'X$.

7. Vamos a calcular las coordenadas de las filas y columnas F y G de los 3 tipos de Biplot

- a. SQ Biplot ($c=0.5$) (biplot simétrico) $F=VD_{\lambda}^{1/4}$ $G=UD_{\lambda}^{1/4}$

```
> F1 <- svd(X)$u[,1]*sqrt(svd(X)$d[1])
> F1
[1] -1.3571819  0.3012074  1.5839617 -0.5279872
> F2 <- svd(X)$u[,2]*sqrt(svd(X)$d[2])
> F2
[1] -4.082483e-01 -4.082483e-01  1.273997e-14  8.164966e-01
> F <- cbind(F1,F2)
> F
      F1      F2
[1,] -1.3571819 -4.082483e-01
[2,]  0.3012074 -4.082483e-01
[3,]  1.5839617  1.273997e-14
[4,] -0.5279872  8.164966e-01

> G1 <- svd(X)$v[,1]*sqrt(svd(X)$d[1])
> G1
[1] 1.246149 1.421812 1.070486
> G2 <- svd(X)$v[,2]*sqrt(svd(X)$d[2])
> G2
[1] 0.8164966 -0.4082483 -0.4082483
> G <- cbind(G1,G2)
> G
      G1      G2
[1,] 1.246149 0.8164966
[2,] 1.421812 -0.4082483
[3,] 1.070486 -0.4082483
F%*%t(G)
      [,1]      [,2]      [,3]
[1,] -2.024583624 -1.7629902 -1.2861771
[2,]  0.042015836  0.5949268  0.4891049
[3,]  1.973851681  2.2520950  1.6956083
[4,]  0.008716106 -1.0840317 -0.8985361
```

- b. JK Biplot ($c=1$) $F=VD_{\lambda}^{1/2}$ $G=U$

```
> F1 <- svd(X)$u[,1]*svd(X)$d[1]
> F1
[1] -2.9486705  0.6544159  3.4413820 -1.1471273
> F2 <- svd(X)$u[,2]*svd(X)$d[2]
> F2
[1] -4.082483e-01 -4.082483e-01  1.273997e-14  8.164966e-01
> F <- cbind(F1,F2)
> F
      F1      F2
[1,] -2.9486705 -4.082483e-01
[2,]  0.6544159 -4.082483e-01
[3,]  3.4413820  1.273997e-14
[4,] -1.1471273  8.164966e-01

> G1 <- svd(X)$v[,1]
> G1
[1] 0.5735637 0.6544159 0.4927115
> G2 <- svd(X)$v[,2]
> G2
[1] 0.8164966 -0.4082483 -0.4082483
> G <- cbind(G1,G2)
> G
      G1      G2
[1,] 0.5735637 0.8164966
[2,] 0.6544159 -0.4082483
[3,] 0.4927115 -0.4082483
F%*%t(G)
      [,1]      [,2]      [,3]
[1,] -2.024583624 -1.7629902 -1.2861771
[2,]  0.042015836  0.5949268  0.4891049
[3,]  1.973851681  2.2520950  1.6956083
```

```
[4,] 0.008716106 -1.0840317 -0.8985361
```

c. GH Biplot (c=0) F=V $G = UD_{\lambda}^{1/2}$

```
> F1 <- svd(X)$u[,1]
> F1
[1] -0.6246689 0.1386365 0.7290486 -0.2430162
> F2 <- svd(X)$u[,2]
> F2
[1] -4.082483e-01 -4.082483e-01 1.273997e-14 8.164966e-01
> F <- cbind(F1,F2)
> F
      F1      F2
[1,] -0.6246689 -4.082483e-01
[2,]  0.1386365 -4.082483e-01
[3,]  0.7290486  1.273997e-14
[4,] -0.2430162  8.164966e-01

> G1 <- svd(X)$v[,1]*svd(X)$d[1]
> G1
[1] 2.707435 3.089088 2.325782
> G2 <- svd(X)$v[,2]*svd(X)$d[2]
> G2
[1] 0.8164966 -0.4082483 -0.4082483
> G <- cbind(G1,G2)
> G
      G1      G2
[1,] 2.707435 0.8164966
[2,] 3.089088 -0.4082483
[3,] 2.325782 -0.4082483
F%*%t(G)
      [,1]      [,2]      [,3]
[1,] -2.024583624 -1.7629902 -1.2861771
[2,]  0.042015836  0.5949268  0.4891049
[3,]  1.973851681  2.2520950  1.6956083
[4,]  0.008716106 -1.0840317 -0.8985361
```

8. Es el momento de responder a la siguiente pregunta; ¿Por qué la 2ª columna de las matrices F y G de las coordenadas de las filas y columnas en los 3 tipos de Biplot, son iguales?
9. Vamos a obtener la matriz estimada de X por el Análisis Biplot, no por el producto de F y G, sino como la reconstrucción de 2º grado de la matriz X

```
> ((svd(X)$d[1]))*(svd(X)$u[,1])%*%(t(svd(X)$v[,1]))+((svd(X)$d[2]))*(svd(X)$u[,2])%
*%(t(svd(X)$v[,2]))
      [,1]      [,2]      [,3]
[1,] -2.024583624 -1.7629902 -1.2861771
[2,]  0.042015836  0.5949268  0.4891049
[3,]  1.973851681  2.2520950  1.6956083
[4,]  0.008716106 -1.0840317 -0.8985361
```

10. Por último comprobar todos los resultados obtenidos con los que aparecen en el documento [Biplot](#) del enunciado.

11. Comprobación de resultados: **otra forma de hacerlo**

```
> X <- matrix(c(-2, 0, 2, 0, -2,1,2,-1,-1,0,2,-1), nrow=4)
> X
      [,1] [,2] [,3]
[1,]   -2    -2   -1
[2,]    0     1    0
[3,]    2     2    2
[4,]    0    -1   -1

> meanX <- apply(X,2,mean)
> meanX
[1] 0 0 0
```

```

> sdX <- apply(X,2,sd)
> sdX
[1] 1.632993 1.825742 1.414214

> t(X)%*%X
      [,1] [,2] [,3]
[1,]    8    8    6
[2,]    8   10    7
[3,]    6    7    6

> X%*%t(X)
      [,1] [,2] [,3] [,4]
[1,]    9   -2  -10    3
[2,]   -2    1    2   -1
[3,]  -10    2   12   -4
[4,]    3   -1   -4    2

> svd(t(X)%*%X)
$d
[1] 22.2819293 1.0000000 0.7180707

$u
      [,1] [,2] [,3]
[1,] -0.5735637 0.8164966 0.06601555
[2,] -0.6544159 -0.4082483 -0.63645361
[3,] -0.4927115 -0.4082483 0.76848471

$v
      [,1] [,2] [,3]
[1,] -0.5735637 0.8164966 0.06601555
[2,] -0.6544159 -0.4082483 -0.63645361
[3,] -0.4927115 -0.4082483 0.76848471

> svd(X%*%t(X))
$d
[1] 2.228193e+01 1.000000e+00 7.180707e-01 5.416122e-16

$u
      [,1] [,2] [,3] [,4]
[1,] -0.6246689 4.082483e-01 0.4394567 0.5
[2,] 0.1386365 4.082483e-01 -0.7510747 0.5
[3,] 0.7290486 -6.938894e-16 0.4674271 0.5
[4,] -0.2430162 -8.164966e-01 -0.1558090 0.5

$v
      [,1] [,2] [,3] [,4]
[1,] -0.6246689 4.082483e-01 0.4394567 -0.5
[2,] 0.1386365 4.082483e-01 -0.7510747 -0.5
[3,] 0.7290486 -1.110223e-16 0.4674271 -0.5
[4,] -0.2430162 -8.164966e-01 -0.1558090 -0.5

> lambda <- diag(sqrt(svd(t(X)%*%X)$d))
> lambda2 <- lambda[-3,1:2]
> lambda
      [,1] [,2] [,3]
[1,] 4.720374 0 0.0000000
[2,] 0.000000 1 0.0000000
[3,] 0.000000 0 0.8473905

> lambda2
      [,1] [,2]
[1,] 4.720374 0
[2,] 0.000000 1

> lambda2^(1/2)
      [,1] [,2]
[1,] 2.172642 0
[2,] 0.000000 1

> V <- svd(X%*%t(X))$v[,1:2]
> V
      [,1] [,2]
[1,] -0.6246689 4.082483e-01
[2,] 0.1386365 4.082483e-01
[3,] 0.7290486 -1.110223e-16
[4,] -0.2430162 -8.164966e-01

> F <- V%*%lambda2^(1/2)
> round(F,2)

```

	[,1]	[,2]
[1,]	-1.36	0.41
[2,]	0.30	0.41
[3,]	1.58	0.00
[4,]	-0.53	-0.82

```
> U <- svd(t(X)%*%X)$u[,1:2]
```

```
> G <- U%*%lambda2^(1/2)
> round(G,2)
```

	[,1]	[,2]
[1,]	-1.25	0.82
[2,]	-1.42	-0.41
[3,]	-1.07	-0.41

```
> F <- V
> round(F,2)
```

	[,1]	[,2]
[1,]	-0.62	0.41
[2,]	0.14	0.41
[3,]	0.73	0.00
[4,]	-0.24	-0.82

```
> G <- U%*%lambda2
> round(G,2)
```

	[,1]	[,2]
[1,]	-2.71	0.82
[2,]	-3.09	-0.41
[3,]	-2.33	-0.41

```
> F <- V%*%lambda2
> round(F,2)
```

	[,1]	[,2]
[1,]	-2.95	0.41
[2,]	0.65	0.41
[3,]	3.44	0.00
[4,]	-1.15	-0.82

```
> G <- U
> round(G,2)
```

	[,1]	[,2]
[1,]	-0.57	0.82
[2,]	-0.65	-0.41
[3,]	-0.49	-0.41

```
> X <- -F%*%t(G)
> round(X,1)
```

	[,1]	[,2]	[,3]
[1,]	-2	-1.8	-1.3
[2,]	0	0.6	0.5
[3,]	2	2.3	1.7
[4,]	0	-1.1	-0.9