

Ejemplo (datos reales: 34 Estados sobre los que se observan variables socio-demográficas y económicas)

Objetivos:

1. Ayudar a comprender los conceptos relacionados con un análisis de componentes principales. Interpretación de resultados.
2. Aprender a ejecutar con R el ACP. Familiarizarse con los términos y funciones ligadas a un ACP.

Objetivo del ACP:

Datos

Exploración previa al análisis ACP

Grafico caja

Correlaciones observadas entre pares de variables:

Determinante de la matriz de correlaciones

ACP

Función prcomp()

Función princomp()

Puntuaciones de las observaciones en las componentes

Gráfico de dispersión de las componentes Y1 e Y2:

Análisis mediante extracción de unas pocas componentes:

Matriz de componentes C

Gráficos de componentes

La matriz de correlaciones reproducidas y la matriz residual

Matriz de comunalidades

Rotaciones de la solución

La función varimax()

Uso de la matriz de componentes de la solución no rotada, C, como input en la función varimax

Matriz de componentes rotados (C^R):

Tabla de coeficientes para el cálculo de las puntuaciones en las componentes:

Ejemplo 2: (archivo estdo3)

En el conjunto constituido por 34 Estados del mundo se han observado las 11 variables siguientes.

El archivo **estdo3** contiene dichas variables (las cuales se han estandarizado previo uso):

Variables estandarizadas (Z)

Ztlibrop: número de libros publicados
Ztejerci: Cociente entre el número de individuos en ejército de tierra y población total del estado.
Ztpobact: cociente entre población activa y total
Ztenergi: tasa de consumo energético
Zpservi: Población del sector servicios
Zpagricu: Población del sector agrícola
Ztmedico: Tasa de médicos por habitante
Zespvida: Esperanza de vida
Ztminfan: tasa de mortalidad infantil
Zpodbdens:Densidad de población
Zpoburb: Porcentaje de población urbana

Tomadas para 34 Estados del mundo.

Objetivo del análisis:

1. Seleccionar un número pequeño de componentes que resuma las 11 variables observadas en unas pocas dimensiones latentes, procurando que la información perdida no sea de mucha importancia.
2. Intentar interpretar las componentes principales derivadas del análisis

Datos

```
># 11 variables Ztlibrop a Zpoburb observadas en 34 Estados del mundo. No olvide usar separador decimal ,  
#ACP estados3  
a=read.table("estdo3.DAT", header=T, sep="\t",dec=".")  
x=a[,-1]  
row.names(x)=as.character(a$pais)
```

Dado que las variables presentan unidades de medida muy diversas así como varianzas muy distintas, se han estandarizado previamente para evitar que algunas puedan anular o minimizar los efectos de otras. El análisis ACP se basará, por tanto, en dichas variables. O lo que es igual, ACP de matriz de correlaciones de variables sin estandarizar.

Exploración previa al análisis ACP

La matriz de correlaciones observadas entre las variables, R, presenta en sus elementos fuera de la diagonal, lo que podríamos llamar información redundante o compartida por pares de variables originales.

Otro estadístico que sirve de indicador de la adaptación de los datos a la aplicación de la técnica es el determinante de la matriz de correlaciones. Su valor es muy bajo.

```
>#Exploración de los datos
>plot(x)
```



```
>cor(x,use = "pairwise") #Hay algún dato missing, por lo usamos la opción "pairwise"
> round(cor(x,use = "pairwise"),3)
```

	zpobdens	ztm nfan	zespvida	zpoburb	ztmedico	zpagri cu	zpservi	ztl i brop
zpobdens	1.000	-0.224	0.161	0.040	-0.014	0.019	-0.095	0.271
ztm nfan	-0.224	1.000	-0.967	-0.757	-0.751	0.752	-0.590	-0.736
zespvida	0.161	-0.967	1.000	0.787	0.736	-0.754	0.612	0.712
zpoburb	0.040	-0.757	0.787	1.000	0.635	-0.938	0.890	0.667
ztmedico	-0.014	-0.751	0.736	0.635	1.000	-0.675	0.445	0.621
zpagri cu	0.019	0.752	-0.754	-0.938	-0.675	1.000	-0.907	-0.672
zpservi	-0.095	-0.590	0.612	0.890	0.445	-0.907	1.000	0.509
ztl i brop	0.271	-0.736	0.712	0.667	0.621	-0.672	0.509	1.000
ztejerci	0.144	-0.108	0.126	0.104	0.231	-0.035	-0.009	0.156
ztpobact	0.189	-0.603	0.541	0.155	0.534	-0.147	-0.056	0.426
ztenergi	-0.090	0.695	0.667	0.582	0.651	-0.697	0.559	0.647
ztejerci	0.144	0.189	-0.090					
ztpobact	-0.108	-0.603	-0.695					
ztenergi	0.126	0.541	0.667					
zpoburb	0.104	0.155	0.582					
ztmedico	0.231	0.534	0.651					
zpagri cu	-0.035	-0.147	-0.697					
zpservi	-0.009	-0.056	0.559					
ztl i brop	0.156	0.426	0.647					
ztejerci	1.000	0.026	-0.105					
ztpobact	0.026	1.000	0.598					
ztenergi	-0.105	0.598	1.000					

Determinante de la matriz de correlaciones

```
>det(cor(x,use = "pairwise"))#valores bajos son indicio de existencia de correlaciones entre variables  
[1] 1.191599e-06
```

Análisis de componentes principales princomp(): ACP

Función prcomp()

```
> acp=princomp(~.,data=x,na.action=na.exclude,cor=T)#Usamos la opción con fórmula. Hay algún NAs.  
> summary(acp)
```

Se desea obtener las componentes principales (\mathbf{Y}) o combinaciones lineales de coeficientes, $\mathbf{A}_{11 \times 11}$, de las variables originales (\mathbf{Z}), tal que $\mathbf{Y} = \mathbf{ZA}$ con $\mathbf{Y}_{34 \times 11}$ (componentes principales) y $\mathbf{Z}_{34 \times 11}$ (variables originales).

Así, por ejemplo, $y_1 = \mathbf{Z}\mathbf{a}_1$ se obtiene de modo que alcanza la mayor varianza posible; es decir

$$V(Y_1) = \frac{1}{N-1} Y_1' Y_1 = \frac{1}{N-1} \mathbf{a}_1' \mathbf{Z}' \mathbf{Z} \mathbf{a}_1 = \mathbf{a}_1' \mathbf{R} \mathbf{a}_1 = \lambda_1 = 6,103$$

(véase el autovalor correspondiente a la componente **1** en tabla **Varianza total explicada**). La varianza del conjunto de variables observadas (Z) proyectada sobre el vector a_1 es $\lambda_1 = 6,103$

La primera componente o combinación lineal, con el mayor valor propio, es la que mejor resume la información contenida en los datos.

La segunda componente, que debe maximizar la varianza después de la extracción de Y_1 , se obtendría calculando el vector a_2 tal que:

$y_2 = \mathbf{Z}\mathbf{a}_2$ e Y_2 está incorrelacionado con Y_1

$$V(Y_2) = (1/N) Y_2' Y_2 = (1/N) \mathbf{a}_2' \mathbf{Z}' \mathbf{Z} \mathbf{a}_2 = \mathbf{a}_2' \mathbf{R} \mathbf{a}_2 = \lambda_2 = 1,617$$

$$\mathbf{a}_2' \mathbf{a}_2 = 1$$

De modo similar, la tercera componente, Y_3 , presenta varianza igual a **1,202**.

```
> acp=princomp(~.,data=x,na.action=na.exclude,cor=T)#equivale a estandarizar
```

```
> summary(acp)
```

```
Importance of components:
```

	Comp. 1	Comp. 2	Comp. 3	Comp. 4	Comp. 5	Comp. 6	Comp. 7	Comp. 8	Comp. 9	Comp. 10	Comp. 11
Standard deviation	2.4703503	1.2715183	1.0963014	0.96165926	0.6295387						
Proportion of Variance	0.5547846	0.1469781	0.1092615	0.08407168	0.0360290						
Cumulative Proportion	0.5547846	0.7017627	0.8110242	0.89509589	0.9311249						
Standard deviation	0.5364019	0.49001802	0.34597391	0.230304892	0.199295299						
Proportion of Variance	0.0261570	0.02182888	0.01088163	0.004821849	0.003610783						
Cumulative Proportion	0.9572819	0.97911077	0.98999240	0.994814247	0.998425031						
Standard deviation	0.131623180										
Proportion of Variance	0.001574969										
Cumulative Proportion	1.000000000										

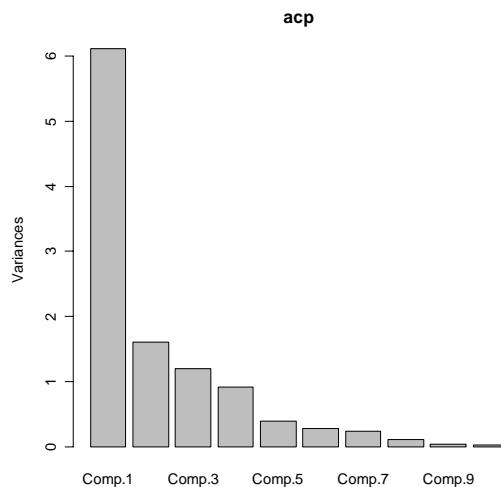
Las 3 primeras componentes tienen varianza superior a 1, tal como muestra el resultado. La cuarta componente presenta un valor muy próximo a 1 (con un valor propio o varianza igual a 0.92):

Valores propios o varianzas de las componentes:

```
> summary(acp)$sd^2
```

Comp. 1	Comp. 2	Comp. 3	Comp. 4	Comp. 5	Comp. 6	Comp. 7
6.10263079	1.61675875	1.20187676	0.92478853	0.39631896	0.28772697	0.24011766
Comp. 8	Comp. 9	Comp. 10	Comp. 11			
0.11969795	0.05304034	0.03971862	0.01732466			

```
> plot(acp)
```



Cada k-ésimo valor propio o **autovalor** ($k=1, \dots, 11$) se interpreta como la parte de la varianza que el k-ésimo **eje principal** (o sea, la correspondiente componente principal) explica. Y el cociente **autovalor / p**, como la proporción correspondiente a dicha componente; muestra, en consecuencia, la importancia de esta componente en el conjunto.

En particular, para la primera componente tenemos: $6,103 / 11 = 0,55478$ (véase **% de la varianza en Varianza total explicada**)

Matriz de vectores propios:

Los **vectores propios** de la matriz de correlaciones de X con la función **princomp** son las columnas de la matriz **Loadings**

```
> loadings(acp) # Vectores propios: coeficientes de combinaciones lineales que proporcionan componentes
```

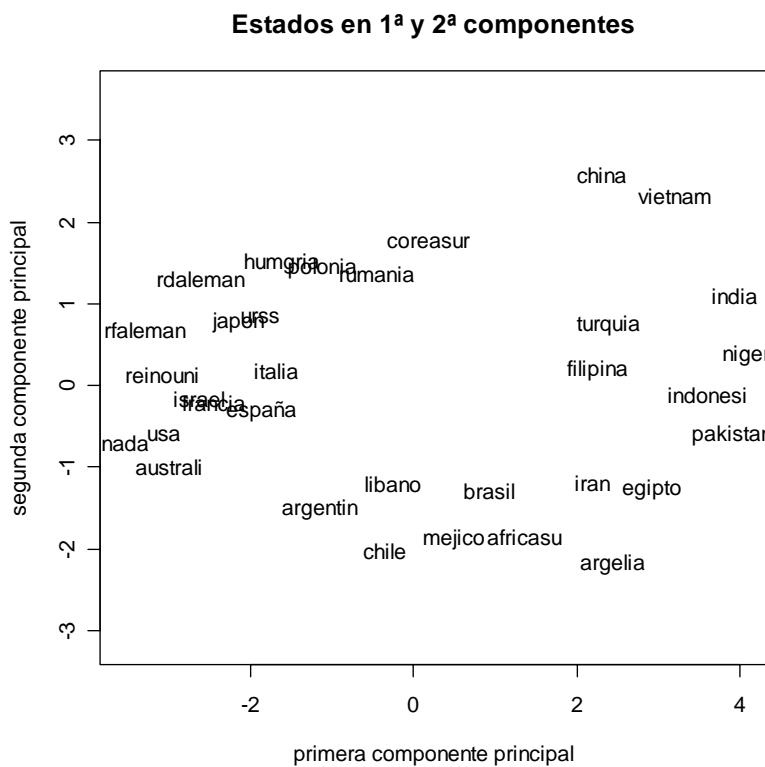
Gráfico de dispersión de las componentes Y1 e Y2:

Pueden realizarse gráficos con las puntuaciones en las componentes principales y visualizar qué casos destacan en determinadas componentes:

```

> require(MASS)
> eqscplot(predict(acp)[,1:2],type="n",xlab="primera componente principal"
+ ,ylab="segunda componente principal")#Gráfico que usa la misma escala en los ejes
> text(predict(acp) [,1:2],labels=row.names(x))
> title(main="Estados en 1a y 2a componentes")

```



Análisis con extracción de 3 componentes

Sólo tres componentes capturan una variabilidad total del 81% (columna **% acumulado**). Esto supone que se puede reducir la dimensionalidad de los datos al pasar de 11 variables observadas a trabajar con sólo 3, sin distorsionar demasiado la información inicial (habrá 19% de variabilidad en los datos originales del que las tres componentes extraídas no pueden dar cuenta). En sólo 3 dimensiones puede registrarse el 81% de la variabilidad original, de modo que los tres factores o componentes explican el 81% de la variabilidad total.

En principio, se prescinde de las componentes asociadas a los valores propios con autovalores inferiores a 1. No obstante, dado que el cuarto autovalor está próximo a 1, convendrá examinar también las posibles ventajas e inconvenientes de su inclusión¹.

La matriz de componentes o matriz factorial

Un output usual en ACP desde la perspectiva del análisis factorial, que es más ilustrativo que la matriz de vectores propios, es la **matriz de componentes** (o **matriz factorial**). La

¹ Aumentar el número de componentes supone aumentar la dimensionalidad de la información resumida en las componentes. No obstante, a veces, un subgrupo de variables importantes podría no quedar bien representado si se omite una componente que recoge la variabilidad del mismo.

relación entre una y otra es simplemente para cada columna un factor de proporcionalidad igual a la raíz del correspondiente valor propio.

Sus valores representan **correlaciones** entre cada una de las variables y cada una de las componentes. Las filas representan las variables y las columnas, las componentes.

Estos coeficientes reciben también el nombre de **pesos**, ponderaciones, **saturaciones**² o **cargas factoriales (factor loading)**.

Siguiendo el criterio de Kaiser seleccionaremos las componentes cuyos autovalores superen el valor 1. En este caso, hay 3.

La **matriz de componentes** contiene las **correlaciones** entre las **variables originales (X)** y las **componentes (Y)**. Se puede obtener, por tanto con la función cor, cor(X,Y)

Tomamos las 3 primeras componentes (81% de variabilidad)

```
> C=cor(x,predict(acp)[,1:3], use = "pairwise") #Matriz de componentes
> C
      Comp. 1       Comp. 2       Comp. 3
zpoedbns -0.08466927  0.53649427  0.535579714
ztmi_nfam  0.92773936 -0.20556883 -0.002878376
zespvida -0.92103278  0.14078899  0.021249026
zpoburb   -0.88727602 -0.33731703  0.188105631
ztmedico  -0.80960016  0.17208428 -0.063954881
zpagridu   0.90305814  0.37281485 -0.075169981
zpservi    -0.75511812 -0.58783056  0.123199006
ztl_ibrop -0.82082940  0.18745282  0.131091878
ztejerci   -0.11265240  0.25221115  0.704759043
ztpobact  -0.47659619  0.73300090 -0.403427946
ztenergi  -0.80276787  0.05368212 -0.421478772
```

Concretamente la **Matriz de componentes C** muestra, por ejemplo, que la tasa de mortalidad infantil (TMINFAN) tiene un coeficiente de correlación con la primera componente igual a 0,928. Las variables TMINFAN y PAGRICUL tienen correlaciones altas con la primera componente de signo positivo, mientras que las variables ESPVIDA, POBURB, TLIBROPU, TMEDICOS, TENERGIA y PSERVI presentan también correlaciones altas pero de distinto signo.

Lógicamente, si alguna de las variables presentara un valor igual a 1, su variabilidad sería explicada totalmente por el factor³.

Puede considerarse que la suma de los cuadrados de los pesos factoriales por **columna** es una medida de la varianza de la matriz R que viene **explicada** por esa **componente principal**.

² Especialmente en el contexto del Análisis Factorial.

³ Existe solapamiento perfecto o variabilidad total compartida entre ellas.

```
> apply(C*C,2,sum)#Varianzas explicadas por las componentes
```

Comp. 1	Comp. 2	Comp. 3
6. 102631	1. 616759	1. 201877

$$(-0.08466927)^2 + (0.92773936)^2 + (-0.92103278)^2 + \dots + (-0.80276787)^2 = \mathbf{6,103}$$

(Recuerde que cada columna j de C es un vector propio multiplicado por la raíz de λ_j).

Esto indica que el valor más alto que puede alcanzar un valor propio o autovalor es **p** (número de variables)⁴

Normalmente, es preciso efectuar una rotación de los ejes en la solución inicial para intentar mejorar la interpretación de las componentes.

Los **gráficos de componentes** visualizan la tabla anterior. Los presentamos en planos, de modo que puedan interpretarse más claramente.

Comunalidad

```
> apply(C*C,1,sum)#Comunalidades
```

zpobdens	ztminfan	zespvi da	zpoburb	ztmedico	zpagricu	zpservi	ztlibrop
0.5818406	0.9029672	0.8685744	0.9364252	0.6891557	0.9601554	0.9309261	0.7260845
ztejerci	ztpobact	ztenergi					
0.5729863	0.9271884	0.8249624					

Otro resultado útil es la communalidad. La **comunalidad** de una variable observada es la $\sum_{i=1}^k r_{ij}^2$, la **proporción de varianza explicada** por los **factores comunes**. (O coeficiente R suponiendo las variables X_i combinaciones lineales de las componentes principales extraídas)

En ACP la communalidad inicial es siempre 1. Se supone un número de componentes igual al de variables. Tras la **Extracción** de un número k menor de componentes, la communalidad de cada variable es la proporción de varianza explicada por las k componentes extraídas; refleja el coeficiente de correlación múltiple al cuadrado de cada variable como si fuera predicha por los k factores o componentes extraídos. Puede observarse que con 3 componentes extraídos, las variables mejor representadas son PAGRICUL, PSERVI y TPOBACTI con valores iguales a 0,960, 0,931 y 0,927, respectivamente. Las peor representadas son TEJERCIT y POBDENS.

Se obtiene a partir de la matriz factorial o matriz de componentes (que notaremos con C). Es igual a la suma⁵ de los cuadrados de las ponderaciones factoriales de cada variable (fila). (Véase **Matriz de componentes C**)

⁴ Correspondría al hipotético caso en que todas las variables tuviesen ponderación igual a uno en el factor o componente.

⁵ Dado que las componentes principales no están correlacionadas.

Por ejemplo, la variable TPOBACTI tiene una comunalidad igual a:

$$0,927 = 0,477^2 + 0,733^2 + (-0,403)^2$$

Por tanto el 92,7 % de la variabilidad de TPOBACTI viene explicado por las 3 componentes principales. Representa, pues, la varianza que comparte con los factores.

Cuanto más se aproxima a cero la comunalidad de una variable, peor representada es por las componentes. Valores próximos a 1, por el contrario, indican que la variabilidad de la variable queda totalmente representada por las componentes.

La matriz de correlaciones reproducidas y la matriz residual

La matriz R (observada) y la matriz R* (reproducida):

En general, si tomamos las 11 componentes, se obtiene:

$$\begin{aligned} RA &= AD \text{ con } A'A = I; \text{ o bien, las expresiones equivalentes:} \\ A'RA &= D \text{ y } R = ADA' = C C' \end{aligned}$$

Donde D representa una matriz diagonal (constituida por los autovalores asociados a las distintas componentes). La suma de los elementos diagonales vale 11 (cumpliéndose que traza de R = traza de D = 11). A es la matriz de vectores propios⁶. C es la matriz de componentes que expresa las correlaciones entre variables y componentes.

Otro modo de expresar R = ADA' es mediante:

$$R = \lambda_1 a_1 a'_1 + \lambda_2 a_2 a'_2 + \dots + \lambda_{11} a_{11} a'_{11}. \text{ (Según (5.1_4)).}$$

Donde a_i es el vector propio px1.

Si despreciamos todas las componentes desde la 4 en adelante, tendremos una aproximación de la matriz R, sumando las tres matrices siguientes:

$$R^* = \lambda_1 a_1 a'_1 + \lambda_2 a_2 a'_2 + \lambda_3 a_3 a'_3$$

$$R^* = 6,103 (\text{matriz } a_1 a'_1) + 1,617 (\text{matriz } a_2 a'_2) + 1,202 (\text{matriz } a_3 a'_3)$$

O bien multiplicando la matriz de componentes rotados por su traspuesta (CC'):

⁶ Puede obtenerse la matriz de vectores propios a partir de la matriz de componentes dividiendo cada columna de dicha matriz por la raíz cuadrada del correspondiente autovalor.

$$R^* = CC' = ADA'$$

(véase matriz de **correlación reproducida** en tabla de **correlaciones reproducidas**)

La matriz de residuos, elementos no diagonales de $R - R^*$, nos indica en cierto modo la posible distorsión en la que se hubiera podido incurrir al describir las variables observadas mediante tres componentes Y_1 , Y_2 e Y_3 .

Matriz residual = $R - R^*$ (elementos no diagonales)

(véase matriz **residual** en tabla de **correlaciones reproducidas**)

> Rrep=C%*%t(C)#Correlaciones reproducidas

> Rep

	zpobdens	ztmi nfan	zespvi da	zpoburb	ztmedi co	zpagri cu
zpobdens	0.581840613	-0.1903791	0.1648962	-0.005098081	0.1266175	0.08329224
ztmi nfan	-0.190379110	0.9029672	-0.8834814	-0.754360463	-0.7862890	0.76137984
zespvi da	0.164896206	-0.8834814	0.8685744	0.773716837	0.7685369	-0.78085521
zpoburb	-0.005098081	-0.7543605	0.7737168	0.936425249	0.6482616	-0.94115853
ztmedi co	0.126617547	-0.7862890	0.7685369	0.648261582	0.6891557	-0.66215296
zpagri cu	0.083292240	0.7613798	-0.7808552	-0.941158532	-0.6621530	0.96015545
zpservi	-0.185449535	-0.5800678	0.6153463	0.891457890	0.5023082	-0.91032840
ztl i brop	0.240276538	-0.8004275	0.7851876	0.689730336	0.6884173	-0.68122565
ztej erci	0.522302678	-0.1583874	0.1542405	0.147447802	0.0895322	-0.06068033
ztpobact	0.217536006	0.5916780	0.5353867	0.099731616	0.5377915	-0.12679478
ztenergi	-0.128965564	-0.7545815	0.7379774	0.614886261	0.6861145	-0.67325002
	zpservi	ztl i brop	ztej erci	ztpobact	ztenergi	
zpobdens	-0.18544954	0.2402765	0.52230268	0.21753601	-0.1289656	
ztmi nfan	-0.58006778	-0.8004275	-0.15838738	-0.59167796	-0.7545815	
zespvi da	0.61534633	0.7851876	0.15424055	0.53358672	0.7379774	
zpoburb	0.89145789	0.6897303	0.14744780	0.09973162	0.6148863	
ztmedi co	0.50230818	0.6884173	0.08953219	0.53779147	0.6861145	
zpagri cu	-0.91032840	-0.6812257	-0.06068033	-0.12679478	-0.6732500	
zpservi	0.93092614	0.5257830	0.02363406	-0.12069583	0.5227028	
ztl i brop	0.52578305	0.7260845	0.23213428	0.47572112	0.6137459	
ztej erci	0.02363406	0.2321343	0.57298633	-0.04575879	-0.1930680	
ztpobact	-0.12069583	0.4757211	-0.04575879	0.92718835	0.5919815	
ztenergi	0.52270281	0.6137459	-0.19306802	0.59198146	0.8249624	

#matriz de residuos

> Resi=cor(x,use = "pairwise")-Rrep #diferencias entre la matriz R de correlaciones de los datos y matriz reproducida

> Resi

	zpobdens	ztmi nfan	zespvi da	zpoburb	ztmedi co
zpobdens	0.418159387	-0.033871059	-0.003661443	0.045341399	-0.140788767
ztmi nfan	-0.033871059	0.097032848	-0.083402044	-0.003134972	0.035370105
zespvi da	-0.003661443	-0.083402044	0.131425559	0.013429204	-0.032408697
zpoburb	0.045341399	-0.003134972	0.013429204	0.063574751	-0.012899529
ztmedi co	-0.140788767	0.035370105	-0.032408697	-0.012899529	0.310844346
zpagri cu	-0.064552521	-0.009218802	0.027317791	0.003136173	-0.012360188
zpservi	0.090303471	-0.010097473	-0.003219363	-0.001442695	-0.057682691
ztl i brop	0.030671070	0.064032998	-0.073197819	-0.022610719	-0.067061136
ztej erci	-0.378779240	0.050296321	-0.028360826	-0.043357878	0.141827653
ztpobact	-0.028217628	-0.011569016	0.007612791	0.055156858	-0.004143106
ztenergi	0.038515625	0.060026706	-0.070838157	-0.032860577	-0.035444366
	zpagri cu	zpservi	ztl i brop	ztej erci	ztpobact
zpobdens	-0.064552521	0.090303471	0.03067107	-0.37877924	-0.028217628
ztmi nfan	-0.009218802	-0.010097473	0.06403300	0.05029632	-0.011569016
zespvi da	0.027317791	-0.003219363	-0.07319782	-0.02836083	0.007612791
zpoburb	0.003136173	-0.001442695	-0.02261072	-0.04335788	0.055156858
ztmedi co	-0.012360188	-0.057682691	-0.06706114	0.14182765	-0.004143106
zpagri cu	0.039844554	0.003109947	0.00909341	0.02582779	-0.020355893
zpservi	0.003109947	0.069073862	-0.01661175	-0.03270851	0.064534414
ztl i brop	0.009093410	-0.016611749	0.27391546	-0.07636061	-0.049238639
ztej erci	0.025827791	-0.032708509	-0.07636061	0.42701367	0.071893185
ztpobact	-0.020355893	0.064534414	-0.04923864	0.07189318	0.072811647
ztenergi	-0.024009374	0.035943782	0.03309585	0.08758459	0.006090014
	ztenergi				
zpobdens	0.038515625				
ztmi nfan	0.060026706				
zespvi da	-0.070838157				
zpoburb	-0.032860577				

```

ztmedi co -0.035444366
zpagri cu -0.024009374
zpservi 0.035943782
ztl i brop 0.033095849
ztej erci 0.087584585
ztpobact 0.006090014
ztenergi 0.175037620

```

Hay 16 residuos no redundantes con valor absoluto mayor a 0.05

Puntuaciones

Nota: Se pueden obtener las puntuaciones en las componentes **como variables** disponibles usar en otras aplicaciones. Las puntuaciones se dan **estandarizadas**. Observe que si multiplicamos la matriz de datos Z por la de valores propios, A, se obtienen las puntuaciones centradas pero con varianza igual a cada correspondiente valor propio, tal como se ha expresado en párrafos anteriores. Para obtener las puntuaciones estandarizadas es preciso dividir cada columna Y_i por la raíz cuadrada del autovalor i-ésimo; una opción para obtener las puntuaciones tipificadas es mediante:

$$Y_{n \times k} D_{k \times k}^{-1/2} = Z_{n \times p} A_{p \times k} D_{k \times k}^{-1/2}$$

Donde $D^{-1/2} = Diag\left[\frac{1}{\sqrt{\lambda_i}}\right]$ es la matriz diagonal que contiene como elementos diagonales los inversos de las raíces cuadradas de los k primeros valores propios.

Puede proporcionarse además la matriz de coeficientes para el cálculo de las puntuaciones en las componentes (Véase más adelante el cálculo de **las puntuaciones en las componentes**).

Rotaciones de la solución

R permite rotar la solución de modo que sea más interpretable.

La función varimax()

La función **varimax** proporciona los **loadings** rotados (obtenidos como el producto de los loadings no rotados por la matriz de rotación) y la **matriz de rotación**.

El input lo constituyen los loadings o la matriz de componentes de la solución no rotada.

Uso de la matriz de componentes de la solución no rotada, C, como input en la función varimax

>rota=varimax(C, normalize = T) # C es la matriz de componentes (correlaciones entre X e Y) en solución no rotada, ya obtenida en párrafos anteriores.

```

> rota
$loadings

```

Loadings:

	Comp. 1	Comp. 2	Comp. 3
zpobdens	0.101	0.177	0.735
ztminfan	0.641	-0.677	-0.184
zespvida	-0.675	0.621	0.167
zpoburb	-0.944	0.201	
ztmedico	-0.548	0.615	
zpagricu	0.950	-0.236	
zpservi	-0.958		-0.117
ztlibrop	-0.593	0.546	0.277
ztejerci	-0.114		0.744
ztpobact	0.102	0.956	
ztenergi	-0.526	0.690	-0.269

	Comp. 1	Comp. 2	Comp. 3
SS Loadings	4.539	3.043	1.339
Proportion Var	0.413	0.277	0.122
Cumulative Var	0.413	0.689	0.811

\$rotmat

	[, 1]	[, 2]	[, 3]
[1,]	0.8100587	-0.5799115	-0.08664594
[2,]	0.5409860	0.6821916	0.49188293
[3,]	-0.2261394	-0.4453283	0.86633923

En un intento de encontrar una solución más interpretable efectuaremos la rotación o giro de los ejes coordenados (que representan a las componentes) tal que las distintas variables, representadas por puntos cuyas coordenadas constituyen los pesos o elementos de la matriz de componentes, “caigan” o se sitúen de forma que se organicen subgrupos claramente definidos y próximos a diferentes ejes⁷

Matriz de componentes rotados (\mathbf{C}^R):

Esta matriz se obtiene a partir de la matriz de componentes sin rotar \mathbf{C} mediante el producto:

$$\mathbf{C}^R = \mathbf{C} \mathbf{T}$$

Donde la matriz \mathbf{T} es la constituida por los coeficientes que definen la rotación ejercida (rota\$rotmat).

Varimax proporciona directamente la **matriz de componentes rotadas** (rota\$loadings).

Loadings:

	Comp. 1	Comp. 2	Comp. 3
zpobdens	0.101	0.177	0.735
ztminfan	0.641	-0.677	-0.184
zespvida	-0.675	0.621	0.167
zpoburb	-0.944	0.201	
ztmedico	-0.548	0.615	
zpagricu	0.950	-0.236	
zpservi	-0.958		-0.117
ztlibrop	-0.593	0.546	0.277
ztejerci	-0.114		0.744
ztpobact	0.102	0.956	
ztenergi	-0.526	0.690	-0.269

La tabla **Matriz de componentes rotados** ofrece un esquema ligeramente distinto de la matriz sin rotar. Es una combinación lineal de la primera y **explica la misma** cantidad de la

⁷ Los distintos ejes se sitúan próximos a las variables en que están **saturadas**; es decir, junto a aquellas que presentan pesos máximos en dichos ejes.

varianza inicial. Las communalidades ⁸son las mismas. No obstante, cambia la variabilidad capturada por cada componente. (Véase tabla de varianza total explicada. Compare suma de las saturaciones al cuadrado de la extracción y la de la rotación).

```
> apply(rota$loadings^2,1,sum)#Comunalidades
```

zpobdens	ztminfan	zespvida	zpourb	ztmedico	zpagricu	zpservi	ztlibrop
0.5818406	0.9029672	0.8685744	0.9364252	0.6891557	0.9601554	0.9309261	0.7260845
ztejerci	ztprobact	ztenergi					
0.5729863	0.9271884	0.8249624					

La suma de las saturaciones al cuadrado de las 3 componentes es la misma, pero la variabilidad capturada por cada componente difiere:

```
> apply(rota$loadings^2,2,sum) #Varianzas explicadas por las componentes
```

Comp. 1	Comp. 2	Comp. 3
4.539149	3.043067	1.339049

Efectivamente, cada componente no explica lo mismo. Por ejemplo, la suma de los valores al cuadrado de la columna primera de la tabla Matriz de componentes rotados es:

$$(0.101)^2 + (0.641)^2 + \dots + (-0.526)^2 = 4,53$$

Observe que la suma obtenida al acumular los valores propios es la misma. Lo cual es lógico, porque la dimensión (igual a 3) es la misma en ambas soluciones. Los puntos están ubicados en tres dimensiones en ambos casos.

Interpretación:

Las variables más importantes para definir la variabilidad registrada en la primera componente son PSERVI, PAGRICUL, POBURB, ESPVIDA, TMINFAN.

Las variables más correlacionadas con la segunda componente son TPOBACTI, TENERGIA, TMINFAN y TMEDICOS

Las variables más correlacionadas con la tercera componente son TEJERCIT y POBDENS
No estamos ante la situación ideal descrita en párrafos anteriores. Ni siquiera la rotación de ejes ha permitido una estructura simple que permita interpretar las componentes de modo más nítido.

Por ejemplo, las variables ESPVIDA, TLIBROPUB, TENERGIA, TMINFAN y TMEDICOS presentan correlaciones altas con las componentes 1 y 2.

En un esfuerzo por caracterizar las componentes según las relaciones observadas con las variables originales podríamos decir lo siguiente:

Es difícil delinear una composición específica para las componentes 1 y 2. ambas parecen contraponer los países más desarrollados a los menos desarrollados. Esperanza de vida alta,

⁸ Geométricamente, podemos imaginar cada variable representada en el espacio tridimensional constituido por las componentes. Sus coordenadas son sus correspondientes correlaciones con ellas. La comunalidad de dicha variable representa la norma o longitud del vector que representa. El giro de los ejes no supone una modificación de la longitud del vector, sólo de las coordenadas del punto respecto a los ejes.

nivel cultural y bienestar social altos frente a bajos (libros publicados, tasa de médicos por habitantes alta frente a baja, tasa de mortalidad infantil baja frente a alta)

Primera componente: Destaca la comparación de países con fuerte sector de servicios y población urbana frente a países con importante sector agrícola. Es decir, cierta estructura que compara sociedades modernas con más primitivas.

Segunda componente: Destaca el potencial humano desde una perspectiva laboral (población activa) y tal vez industrial (consumo energético).

Tercera componente: Indica fundamentalmente **potencial humano**, desde una perspectiva demográfica, reflejado en la densidad de población y el efectivo registrado en su ejército.

Estas componentes podrían usarse en otros estudios como indicadores globales de tipo socioeconómico.

Los gráficos muestran visualmente la información recogida en la tabla **Matriz de componentes rotados** y son de gran ayuda en la interpretación de las componentes:

Representación gráfica de las columnas de la matriz de componentes rotados:

Gráficos de componentes en espacio rotado

Las coordenadas de cada variable vienen dadas en las filas de la tabla **Matriz de componentes rotada** (correlaciones de cada variable con cada componente).

```
plot(rota$loadings[,1],rota$loadings[,2],type="n",xlim=c(-1,1),ylim=c(-1,1))
text(rota$loadings[,1],rota$loadings[,2],labels=row.names(rota$loadings))
title(main="Gráfico de componentes en espacio rotado")
abline(h=0, v=0, col = "gray60")
```

```
plot(rota$loadings[,1],rota$loadings[,3],type="n",xlim=c(-1,1),ylim=c(-1,1))
text(rota$loadings[,1],rota$loadings[,3],labels=row.names(rota$loadings))
title(main="Gráfico de componentes en espacio rotado")
abline(h=0, v=0, col = "gray60")
```

```
plot(rota$loadings[,3],rota$loadings[,2],type="n",xlim=c(-1,1),ylim=c(-1,1))
text(rota$loadings[,3],rota$loadings[,2],labels=row.names(rota$loadings))
title(main="Gráfico de componentes en espacio rotado")
abline(h=0, v=0, col = "gray60")
```

El gráfico muestra las componentes 1 y 2 rotadas. Las coordenadas de cada variable, tal como hemos dicho, son las correlaciones entre variable y componente. Una variable próxima a un eje y alejada del origen indica alta correlación con la componente.

Por ejemplo, los puntos representados por poburb y pserv (a la izquierda) y pagricul (a la derecha) están altamente correlacionados con la primera componente. Los puntos con coordenadas más altas en la componente 2 son tpobacti y tenergia. Los puntos de correlaciones más bajas en dichas componentes son los más próximos al origen (tejercit y pobdens)

Gráfico de componentes en espacio rotado

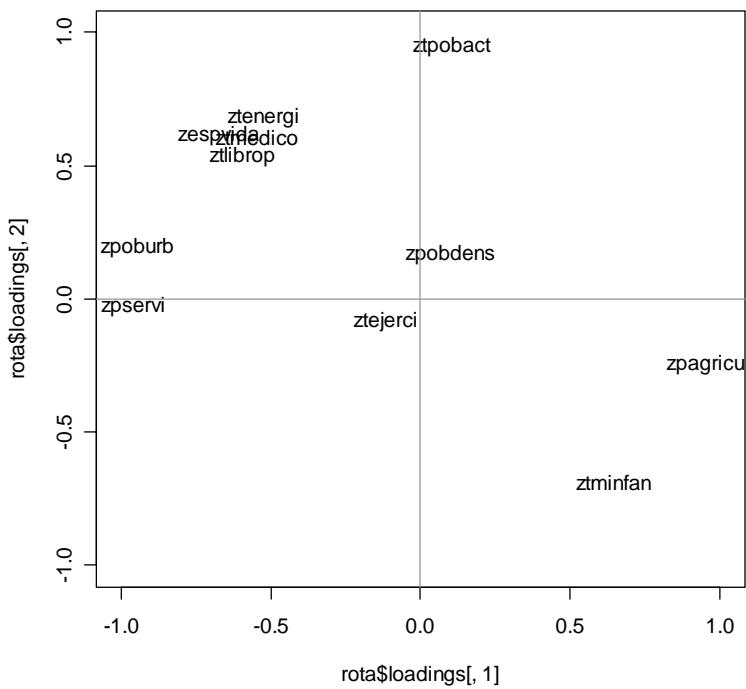
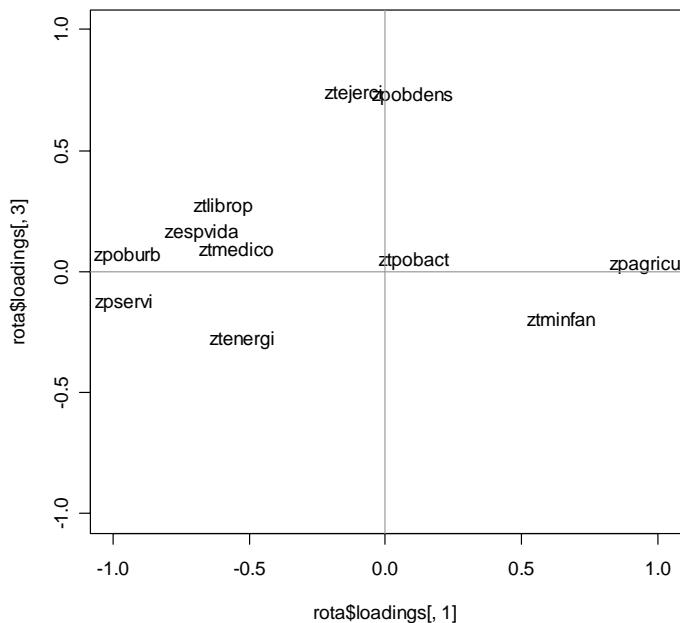
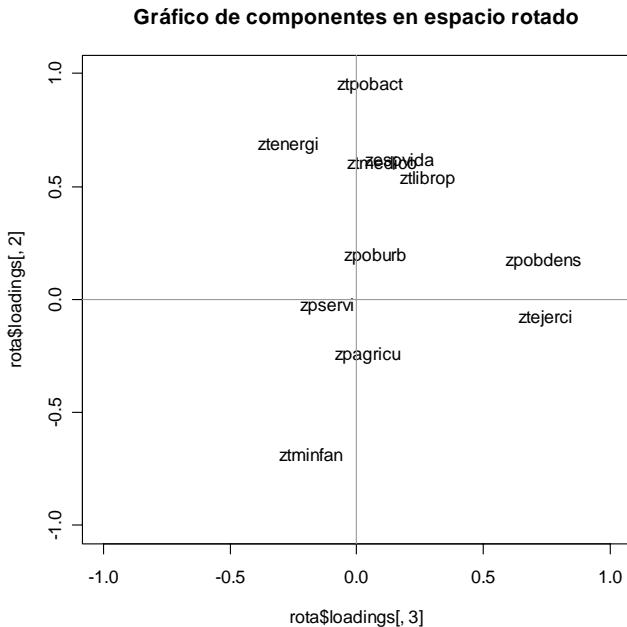


Gráfico de componentes en espacio rotado





La **matriz de transformación de las componentes** muestra la matriz de rotación ($T=\$rotmat$) efectuada, mediante la cual transformamos la solución inicial (tabla Matriz de componentes) en la solución final (tabla Matriz de componentes rotados):

```
$rotmat
 [, 1]      [, 2]      [, 3]
[1, ]  0.8100587 -0.5799115 -0.08664594
[2, ]  0.5409860  0.6821916  0.49188293
[3, ] -0.2261394 -0.4453283  0.86633923
```

Si multiplicamos la matriz C (matriz de componentes) por la matriz T (**matriz de transformación de las componentes**) obtenemos la solución rotada o matriz C^R (**matriz de componentes rotados**)

Obtención de las puntuaciones en las componentes:

A veces interesa conocer las puntuaciones que tienen los individuos en las componentes.

Se obtienen a través de la matriz C (de componentes rotados si se ha efectuado una rotación) mediante

$$Y_{N \times k} = Z_{N \times p} R_{p \times p}^{-1} C_{p \times k} \quad (\text{donde } Y \text{ está formada por la matriz de puntuaciones estandarizadas en las componentes})$$

Los coeficientes que proporcionan la combinación lineal de las variables observadas para obtener las componentes mediante $R^{-1}C$ son:

Tabla de coeficientes para el cálculo de las puntuaciones en las componentes:

Las puntuaciones sin rotar por la matriz de rotación

El resultado es la matriz de puntuaciones estandarizadas en componentes rotadas, dada en la tabla siguiente:

```
> scale(predict(acp)[,1:3])%*% rota$rotmat

> scale(predict(acp)[,1:3])%*% rota$rotmat
      [,1]      [,2]      [,3]
afri casu -0.2211897 -1.06463482 -1.154286257
argelia -0.1525921 -1.76869940 -0.772868263
argentin -0.9402002 -0.41655095 -0.740976950
austral i -1.1623287  0.59009574 -1.076543473
brasil -0.1406334 -0.70828261 -0.862229951
canada -1.0743802  1.26913416 -1.622798879
chile -0.9983720 -1.07206959 -0.551038109
china  2.0915914  1.35577123 -0.098258846
coreasur 0.2998699 -0.08953580  2.591908625
egipto   0.3309670 -1.51186342 -0.225494092
espana   -0.8251721  0.08061296  0.346246029
filipina 0.8258322 -0.39314421 -0.014671518
francia -0.8622797  0.46867818  0.011287623
humgria 0.1869883  1.31701958  0.375700010
india   1.7800302 -0.24168012  0.150418915
indonesi 1.2643138 -0.61052970 -0.686574006
iran    0.1931894 -1.16868322 -0.428876240
israel   -1.6404195 -0.90718024  2.847447672
italia   -0.5149699  0.38332097  0.354176615
japon    -0.4520497  0.72869859  0.739876905
libano   -1.0024816 -1.41054246  1.196015603
marrueco NA         NA         NA
mejico   -0.5644022 -0.99616702 -0.920742480
nigeria 1.6713361 -0.45281389 -0.591199206
pakistan 0.9750060 -1.28236262 -0.215456823
polonia  0.4317143  1.38932765 -0.091387996
rdal eman -0.1314808  1.61358883  0.003363623
reiouni  -1.0138967  0.61803914  0.521507489
rfal eman -0.8987302  0.86455207  0.915107903
rumania  0.6125882  1.18324490 -0.140760414
turquia  1.1040511 -0.12348888  0.171792246
urss     -0.1167349  1.14895463 -0.108758660
usa      -0.8841353  1.07843767 -1.431846891
vietnam  1.8289708  0.12875266  1.509919796
>
```