



## Técnicas de reducción de la dimensión de la información: Componentes Principales.

Miguel Ángel Tarancón Morán & Consolación Quintana Rojo



Área de Estadística  
Económica y Empresarial

Departamento de Economía Aplicada 1  
Universidad de Castilla – La Mancha



- 1 Introducción.
- 2 Obtención de componentes.
- 3 Retención de componentes.
- 4 Significado de las componentes principales.
- 5 Puntuación de componentes principales.



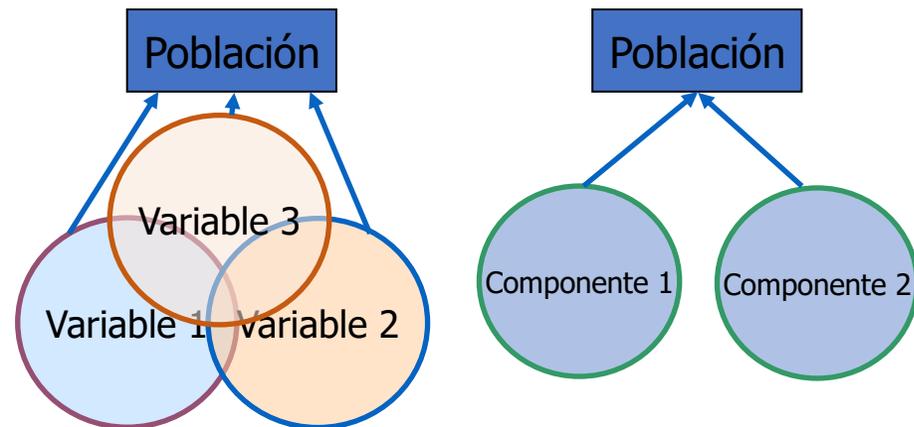
- Muchas veces, en la caracterización de los casos de una población a estudiar (por ejemplo, las empresas de un sector económico), observamos que hay muchas variables que caracterizan a tales casos.
- A veces, el contar con tantas variables hace difícil la caracterización de estos casos. Esto ocurre cuando hay **variables que aportan una información muy parecida** sobre estos agentes.
- Estas técnicas tratan de **reducir el número de variables** que caracterizan los agentes del entorno; **perdiendo la menor cantidad global de información** posible.
- Una de estas técnicas, utilizada habitualmente, es la técnica de **Componentes Principales (CP)**.

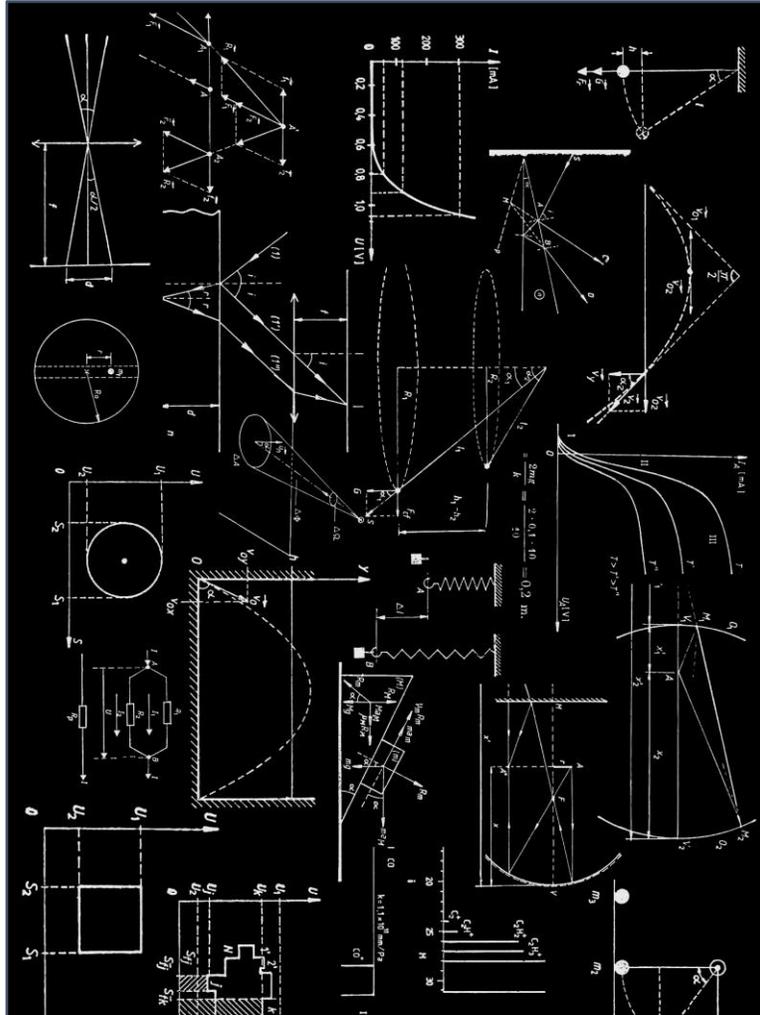


- El objetivo del análisis de **Componentes Principales (CP)** consiste en, a partir de una población caracterizada por  $p$  variables, reducir el número de variables a  $h$ , con  $h < p$ , de manera que las  $h$  nuevas variables, denominadas *componentes principales*:
  - Están **incorrelacionadas** entre sí.
  - Son una **combinación lineal** de las variables originales.
  - En conjunto, recogen la **mayor cantidad posible de información** (varianza) contenida en el conjunto de las variables originales sobre la población a caracterizar.



- Una premisa para que aplicar CP tenga sentido es que las **variables originales estén altamente correlacionadas**, es decir, que contengan información redundante; ya que en caso contrario no haría falta someter a los datos a esta técnica de reducción de la dimensión de la información.
- En definitiva, se trata de intentar eliminar la **información redundante** que tenemos acerca de una población.





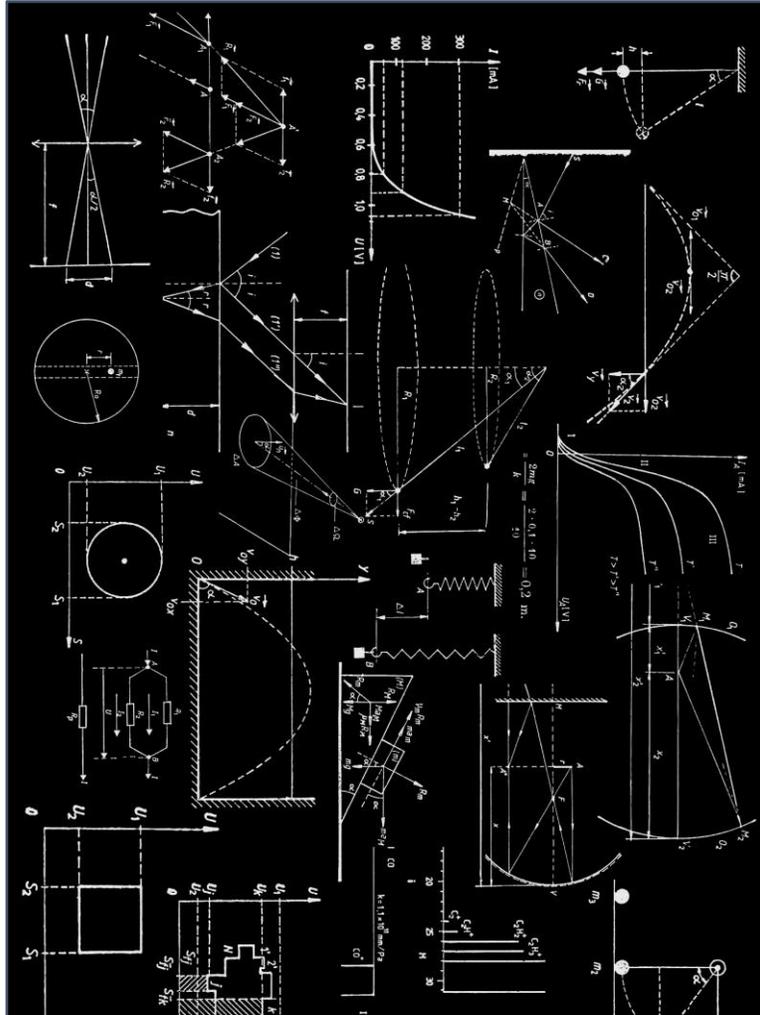
- Matriz de datos:

p variables originales

$$\begin{matrix}
 \text{n individuos} & \begin{matrix} \overbrace{\hspace{1.5cm}}^{x_j} \\ \left( \begin{array}{cccc} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{array} \right) \end{matrix}
 \end{matrix}$$

- Ejemplo:

|              | variable 1 | variable 2 | variable 3 |
|--------------|------------|------------|------------|
| caso 1       | 23         | 13         | 6,5        |
| caso 2       | 31         | 21         | 5          |
| caso 3       | 24         | 14         | 4,5        |
| caso 4       | 35         | 23         | 5          |
| caso 5       | 52         | 41         | 7,5        |
| caso 6       | 46         | 37         | 6          |
| media        | 35,17      | 24,83      | 5,75       |
| desv. típica | 11,75      | 11,70      | 1,13       |



- Matriz de correlaciones:

|             | variable x1 | variable x2 | variable x3 |
|-------------|-------------|-------------|-------------|
| variable x1 | 1,0000      | 0,9961      | 0,6065      |
| variable x2 | 0,9961      | 1,0000      | 0,6092      |
| variable x3 | 0,6065      | 0,6092      | 1,0000      |

- Usualmente las variables originales han sido previamente **tipificadas** (media 0 y desviación típica 1):

**Ejemplo:** Esta es la matriz X con la que trabajamos

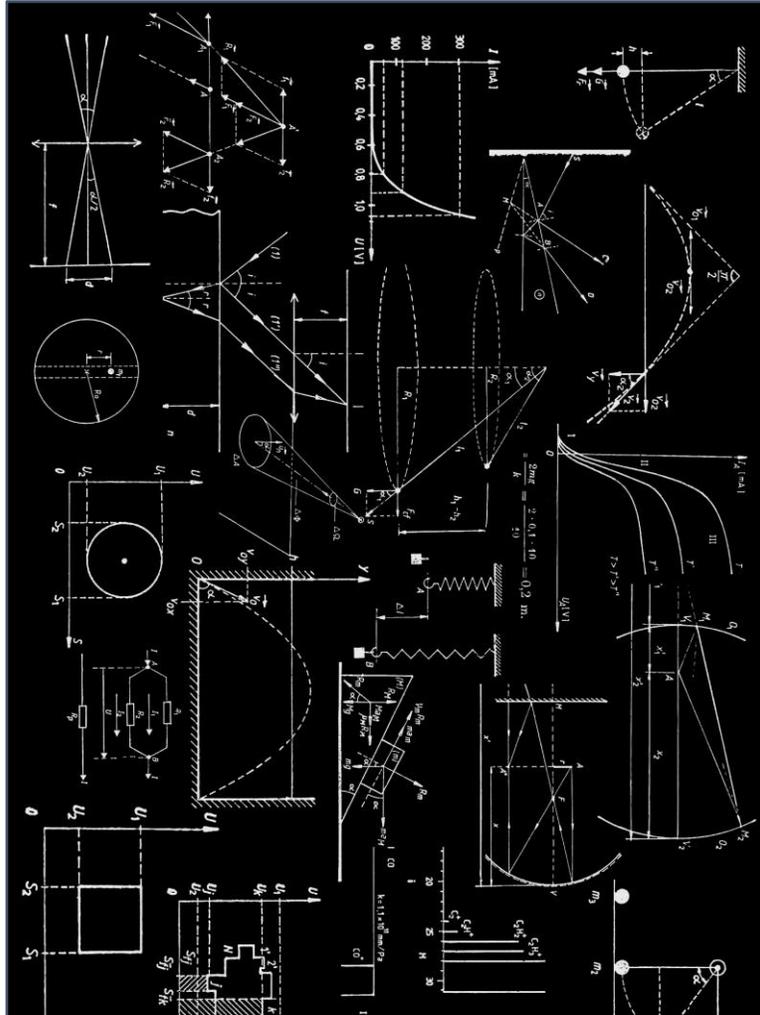
|        | variable 1 | variable 2 | variable 3 |
|--------|------------|------------|------------|
| caso 1 | 23         | 13         | 6,5        |
| caso 2 | 31         | 21         | 5          |
| caso 3 | 24         | 14         | 4,5        |
| caso 4 | 35         | 23         | 5          |
| caso 5 | 52         | 41         | 7,5        |
| caso 6 | 46         | 37         | 6          |



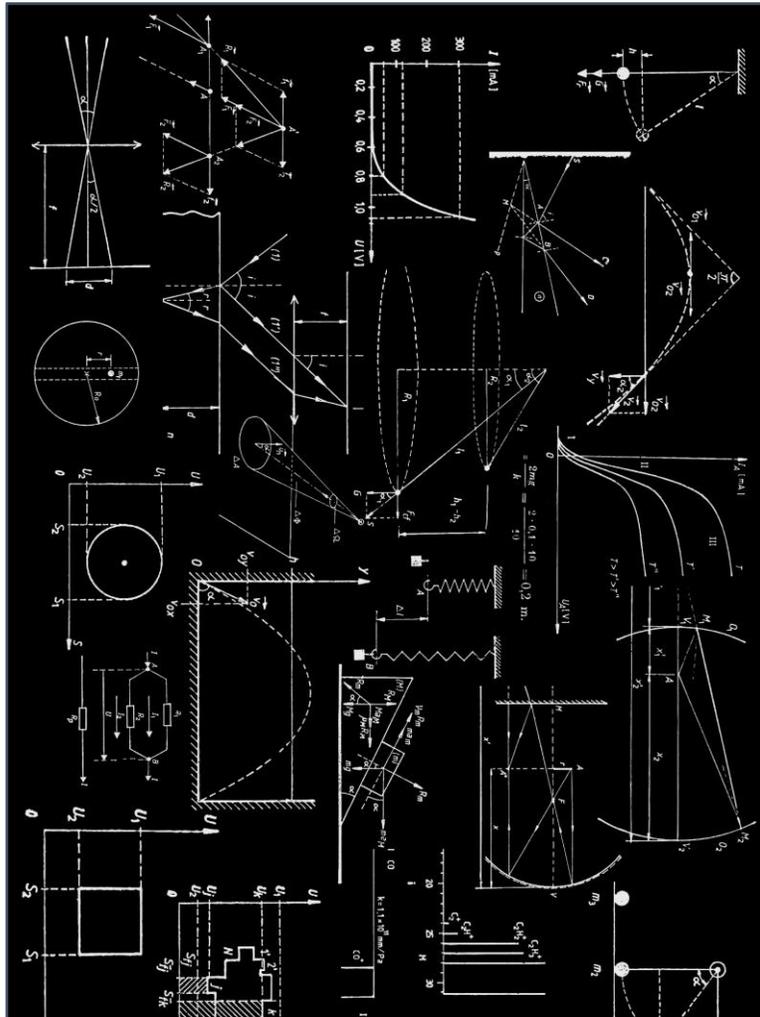
|        | variable 1 | variable 2 | variable 3 |
|--------|------------|------------|------------|
| caso 1 | -1,035     | -1,011     | 0,664      |
| caso 2 | -0,354     | -0,328     | -0,664     |
| caso 3 | -0,950     | -0,926     | -1,107     |
| caso 4 | -0,014     | -0,157     | -0,664     |
| caso 5 | 1,432      | 1,381      | 1,550      |
| caso 6 | 0,922      | 1,040      | 0,221      |

|             |       |       |      |
|-------------|-------|-------|------|
| media       | 35,17 | 24,83 | 5,75 |
| dev. típica | 11,75 | 11,70 | 1,13 |

|             |      |      |      |
|-------------|------|------|------|
| media       | 0,00 | 0,00 | 0,00 |
| dev. típica | 1,00 | 1,00 | 1,00 |



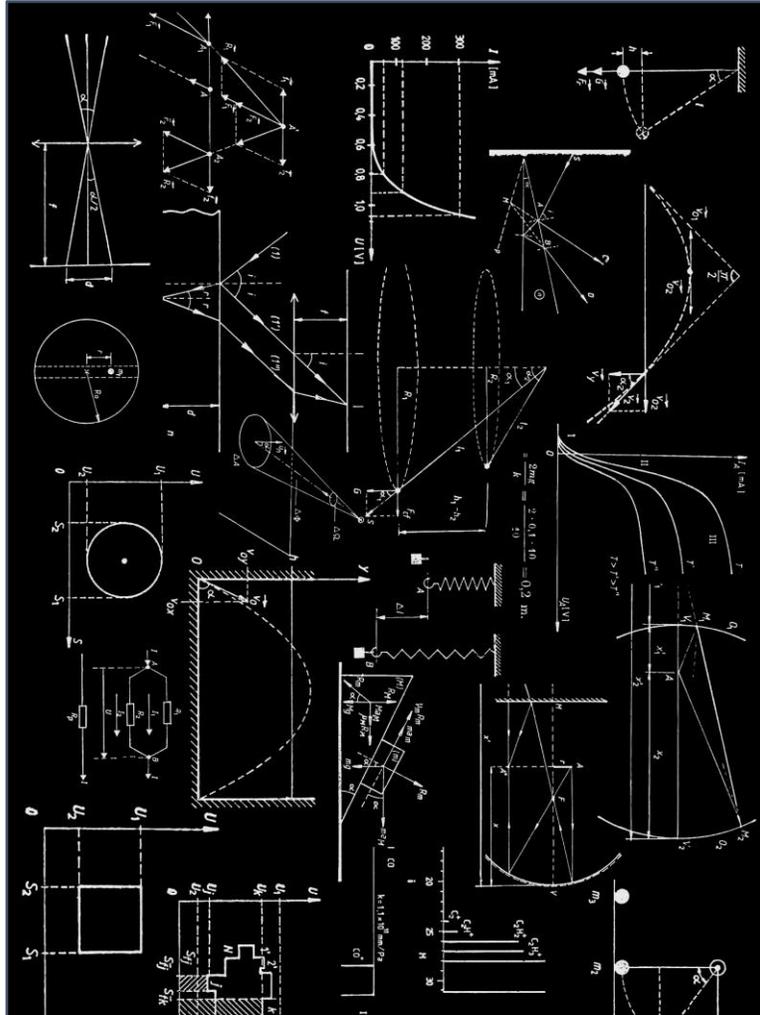
- Las variables originales contienen **información** sobre el comportamiento de los casos de nuestra población o muestra, comportamiento que los caracteriza y distingue.
- Esta información se concreta estadísticamente en las **varianzas** de las diferentes variables. La suma de varianzas (**comunalidad**) nos da una medida de la información que el conjunto de variables poseen sobre los casos.
- Las *componentes* son **combinaciones lineales** de las variables originales. **Hay tantas “componentes” como variables originales.**
- Las componentes **recogen la misma información que las variables originales** (misma suma de varianzas, *comunalidad*); pero de un modo diferente, ya que las componentes están **incorrelacionadas**: no comparten información “duplicada”.



- Componente  $y_k$  para el caso  $i$ :

$$y_{ik} = x_{i1}v_{1k} + x_{i2}v_{2k} + \dots + x_{ip}v_{pk}$$

- *Obtener las componentes* implica obtener el valor de los coeficientes  $v_{jk}$  (**cargas**) para cada una de las  $p$  componentes.
- Estos coeficientes se obtienen según un método iterativo, de modo que **la primera componente es la que recoge mayor parte de la comunalidad o suma de las varianzas de las variables originales**; la segunda componente es la segunda que mayor parte de “comunalidad” recoge, y así sucesivamente hasta la componente  $p$ .
- Cada componente tiene como varianza uno de los **autovalores** de la matriz de varianzas-covarianzas de las variables originales, de mayor a menor:  $\lambda_1, \lambda_2, \dots, \lambda_p$

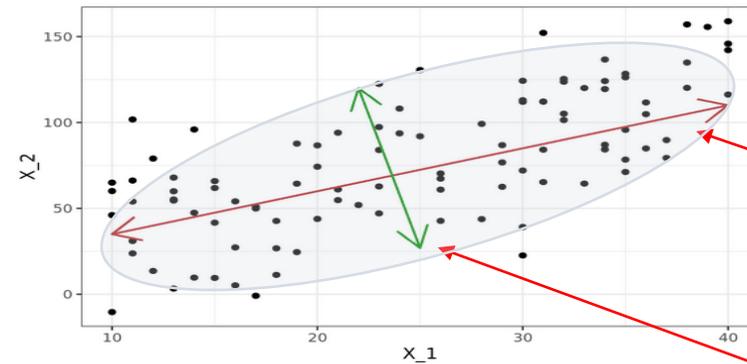


- **Ejemplo:** caso de dos únicas variables originales  $x_1$  y  $x_2$ :

Componente 1:  $y_{i1} = x_{i1}v_{11} + x_{i2}v_{21}$

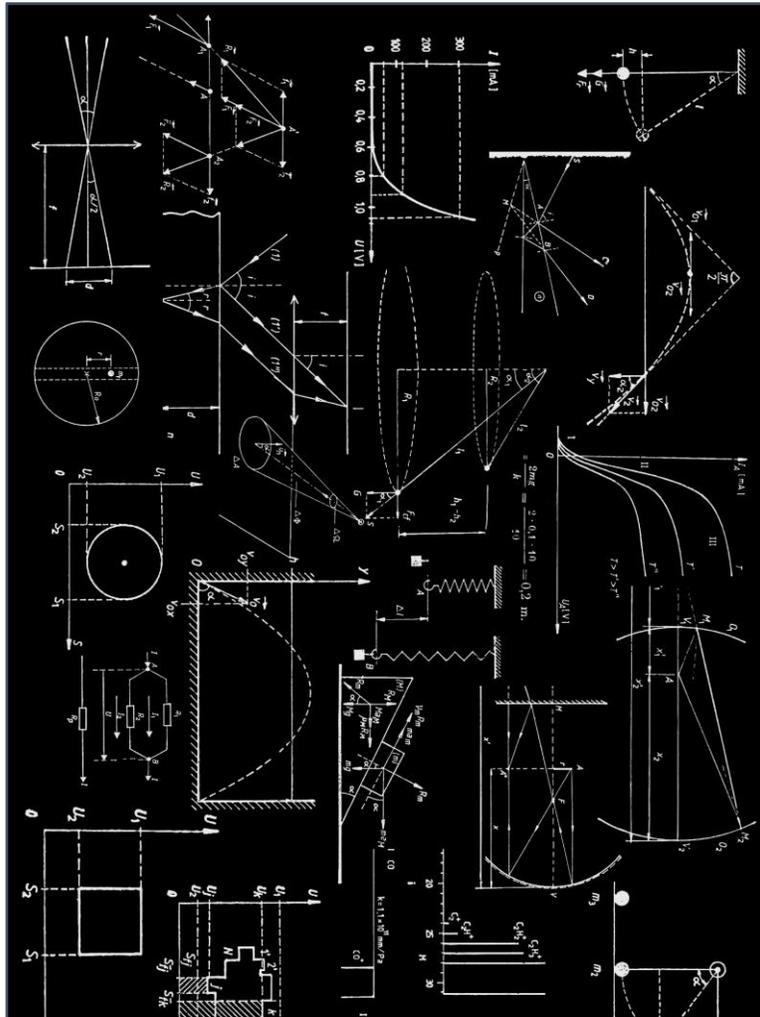
Componente 2:  $y_{i2} = x_{i1}v_{12} + x_{i2}v_{22}$

- Se obtienen los valores de  $v_{j1}$ , de modo que  $y_{i1}$  recoge la mayor parte de la “comunalidad” de las variables originales, que es la varianza de  $y_{i1}$ ,  $\lambda_1$  (mayor autovalor de la matriz de varianzas-covarianzas de las variables originales). Luego se obtienen los  $v_{j2}$ .  $y_{i1}$  y  $y_{i2}$  están incorrelacionadas (geoméricamente, son ortogonales).



Componente 1:  
 $y_{i1} = x_{i1}v_{11} + x_{i2}v_{21}$

Componente 2:  
 $y_{i2} = x_{i1}v_{12} + x_{i2}v_{22}$



- **Ejemplo:** En el ejemplo inicial, teníamos 3 variables originales tipificadas.

|         | $x_{i1}$<br>variable 1 | $x_{i2}$<br>variable 2 | $x_{i3}$<br>variable 3 |
|---------|------------------------|------------------------|------------------------|
| $i = 1$ | -1,035                 | -1,011                 | 0,664                  |
| $i = 2$ | -0,354                 | -0,328                 | -0,664                 |
| $i = 3$ | -0,950                 | -0,926                 | -1,107                 |
| $i = 4$ | -0,014                 | -0,157                 | -0,664                 |
| $i = 5$ | 1,432                  | 1,381                  | 1,550                  |
| $i = 6$ | 0,922                  | 1,040                  | 0,221                  |

Componente 1:  $y_{i1} = x_{i1}v_{11} + x_{i2}v_{21} + x_{i3}v_{31}$   
 Componente 2:  $y_{i2} = x_{i1}v_{12} + x_{i2}v_{22} + x_{i3}v_{32}$   
 Componente 3:  $y_{i3} = x_{i1}v_{13} + x_{i2}v_{23} + x_{i3}v_{33}$

- Cálculo de los coeficientes o **cargas**:

$$y_{i1} = x_{i1} \cdot 0,612 + x_{i2} \cdot 0,613 + x_{i3} \cdot 0,499$$

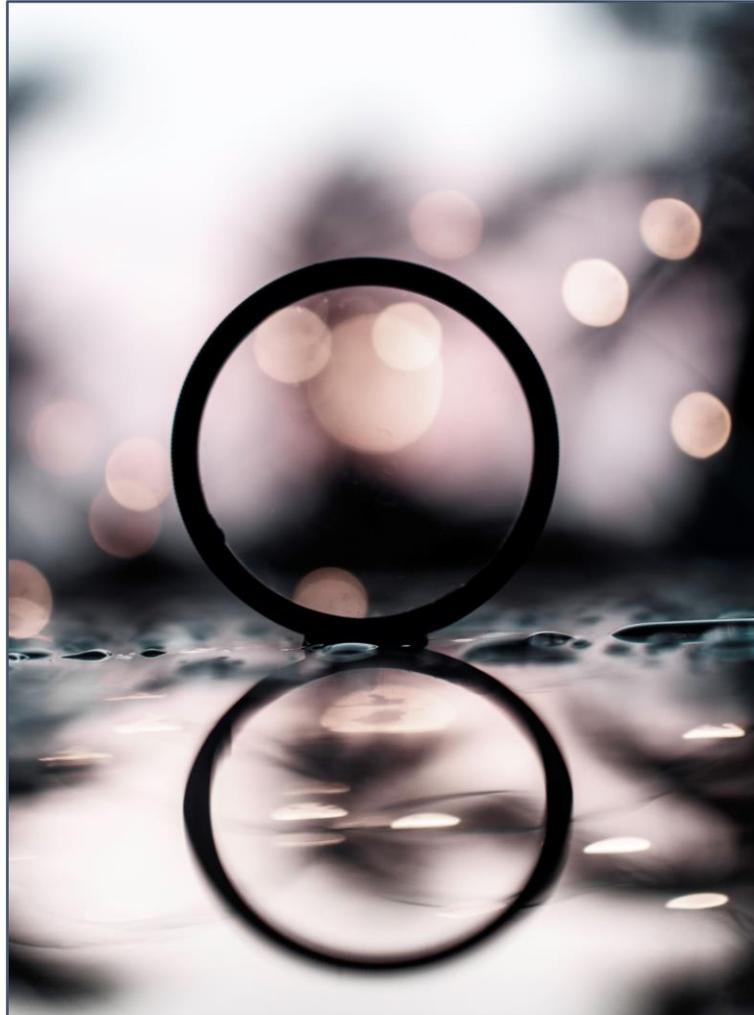
$$y_{i2} = x_{i1} \cdot -0,355 + x_{i2} \cdot -0,351 + x_{i3} \cdot 0,866$$

$$y_{i3} = x_{i1} \cdot 0,706 + x_{i2} \cdot -0,708 + x_{i3} \cdot 0,003$$

- Autovalor asociado a la primera componente (varianza):  $\lambda_1 = 2,492$
- Porcentaje de la comunalidad (suma de las varianzas de las variables originales) recogido por la primera componente: 83,1%.

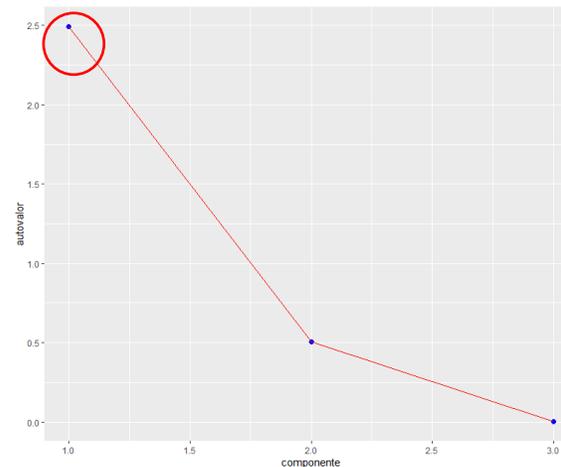


- Del proceso de cálculo de las componentes se obtienen el **mismo número** de estas que de variables originales ( $p$  variables y  $p$  componentes). La diferencia es que las componentes son “variables” **incorrelacionadas** entre sí.
- Las  $p$  componentes recogen el 100% de la suma de las varianzas de las variables originales (*comunalidad*). Pero nosotros **queremos tener menos componentes** que variables originales. Estas serán las **componentes principales**.
- La suma de las varianzas de las componentes coincide con la comunalidad que, si las variables han sido tipificadas, **es igual al número de variables o componentes**.
- La **retención** de componentes consiste en decidir **con cuántas nos quedamos** (aunque se pierda un poco de comunalidad).



- Hay varios procedimientos para identificar el número de componentes a retener. Uno muy extendido: retener los componentes que tengan **varianzas** (autovalores asociados) **mayores que 1**.

- En el **ejemplo**:  $Var(y_{i1}) = \lambda_1 = 2,492$   
 $Var(y_{i2}) = \lambda_2 = 0,504$   
 $Var(y_{i3}) = \lambda_3 = 0,003$



Solo se retiene la componente 1: Solo hay **1 componente principal**, que recoge el 83,1% de la comunalidad (comportamiento de los casos según las variables originales).



- A veces es difícil encontrar un **significado económico** a las componentes, ya que son simples combinaciones lineales de las variables originales.
- Para ello hemos de fijarnos en el valor (absoluto) de las cargas  $v_{jk}$  que las definen; teniendo en cuenta que están en la “misma escala” (porque las variables han sido tipificadas) y, por tanto, son comparables.
- En general, las componentes tendrán una interpretación asociada a las variables originales (X) con las que comparte **cargas con mayor valor absoluto**.



- Con el término de “**puntuaciones**” (“scores”) nos referimos al **valor que toma cada componente principal para cada individuo o caso**.
- Estas puntuaciones son necesarias, a veces, cuando el análisis de componentes principales se usa como **etapa intermedia** de otros análisis (como el análisis clúster, o el análisis de regresión).
- Para obtener las puntuaciones de la componente  $k$  en el individuo  $i$ , no hay más que obtener los valores de las variables originales ( $x$ ) para ese individuo y sustituirlas en la ecuación de la componente.



- **Ejemplo:** vimos que la primera CP era:

$$y_{i1} = x_{i1} \cdot 0,612 + x_{i2} \cdot 0,613 + x_{i3} \cdot 0,499$$

- Así la puntuación o score de la primera CP para el primer individuo será:

$$y_{i1} = -1,035 \cdot 0,612 - 1,011 \cdot 0,613 + 0,664 \cdot 0,499 = -0,922$$



¡Muchas gracias!

This work © 2022 by [Miguel Ángel Tarancón](#) and [Consolación Quintana](#) is licensed under [Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License](#).

