


## 8.2. Reducción de dimensiones



LAB CTIC UNI

**Dr. Manuel Castillo-Cara**  
**Machine Learning con Python**  
**Web: [www.smartcityperu.org](http://www.smartcityperu.org)**

# Índice




- Introducción
- Principal Components Analysis.
- Varianza y selección de  $k$ .
- PCA como algoritmos de aprendizaje no supervisado



LAB CTIC UNI

# Reducción de dimensiones




# 1. Definición

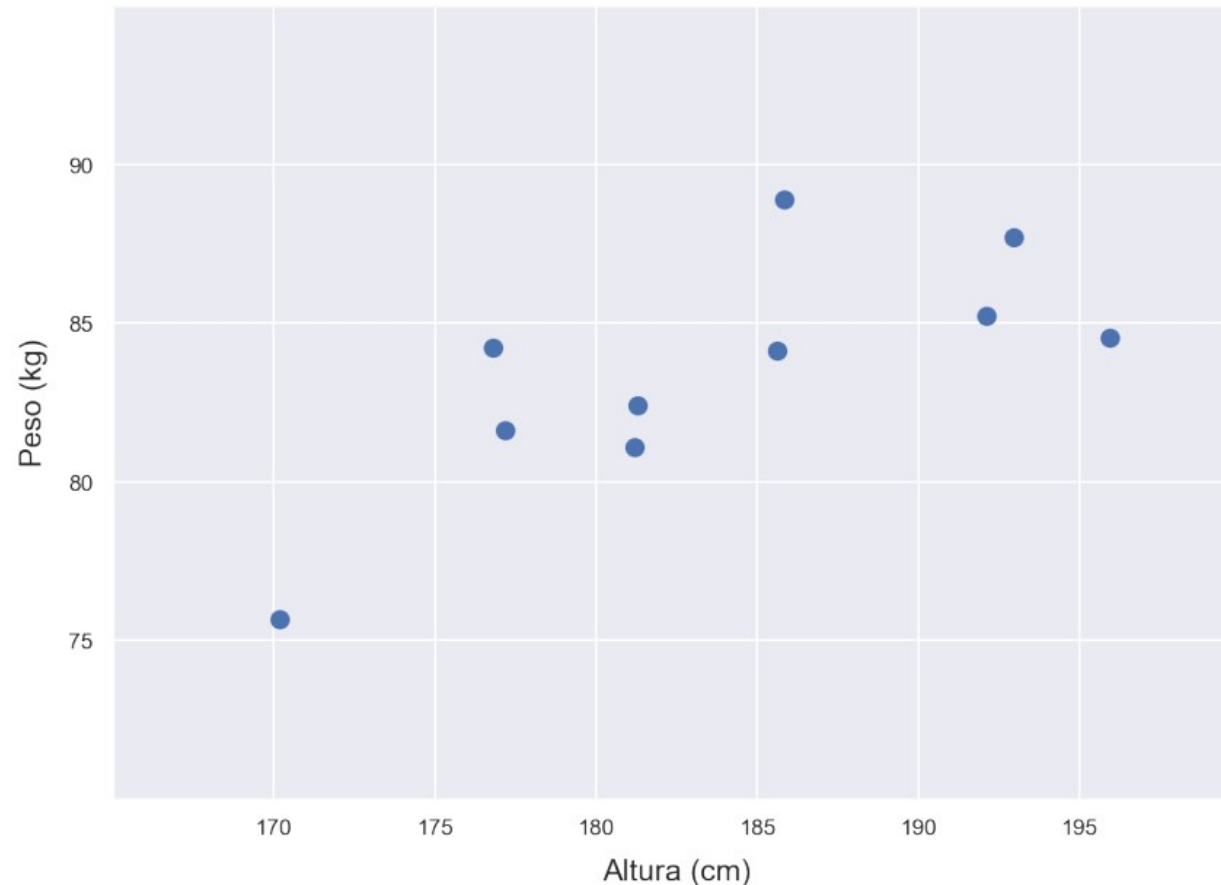
- El análisis de componentes principales es una técnica de **aprendizaje no supervisado**.
- Consiste en crear un conjunto de características (componentes) que representen la información **relevante** que proporcionan las variables originales.
- Se persigue que el número de características sea **sustancialmente menor** que el conjunto de variables.
- Las características han de **maximizar** la proporción de **varianza** de los datos que **retienen** (explican).
  - Maximizan la información que nos proporcionan.

# 2. Datos fuertemente correlacionados

## Ejemplo




- Parte de la información que reflejan, corresponde a **una misma característica**.




# 2. Datos fuertemente correlacionados

## Ejemplo




- Parte de la información que reflejan, corresponde a **una** misma característica.




Característica subyacente que representa a las dos características correlacionadas: tamaño y peso

# 2. Datos fuertemente correlacionados

## Ejemplo




- Definida esa característica, es posible representar los datos en **una sola dimensión**.




La representación unidimensional (tamaño) se puede representar como un vector (rojo)

# 2. Datos fuertemente correlacionados

## Ejemplo



- Definida esa característica, es posible representar los datos en **una sola dimensión**.





Pero ese vector con nuevas instancias tienen asociado un error que va desde el punto del vector hasta el punto original de la intersección de las dos características iniciales



# 2. Datos fuertemente correlacionados


## Ejemplo



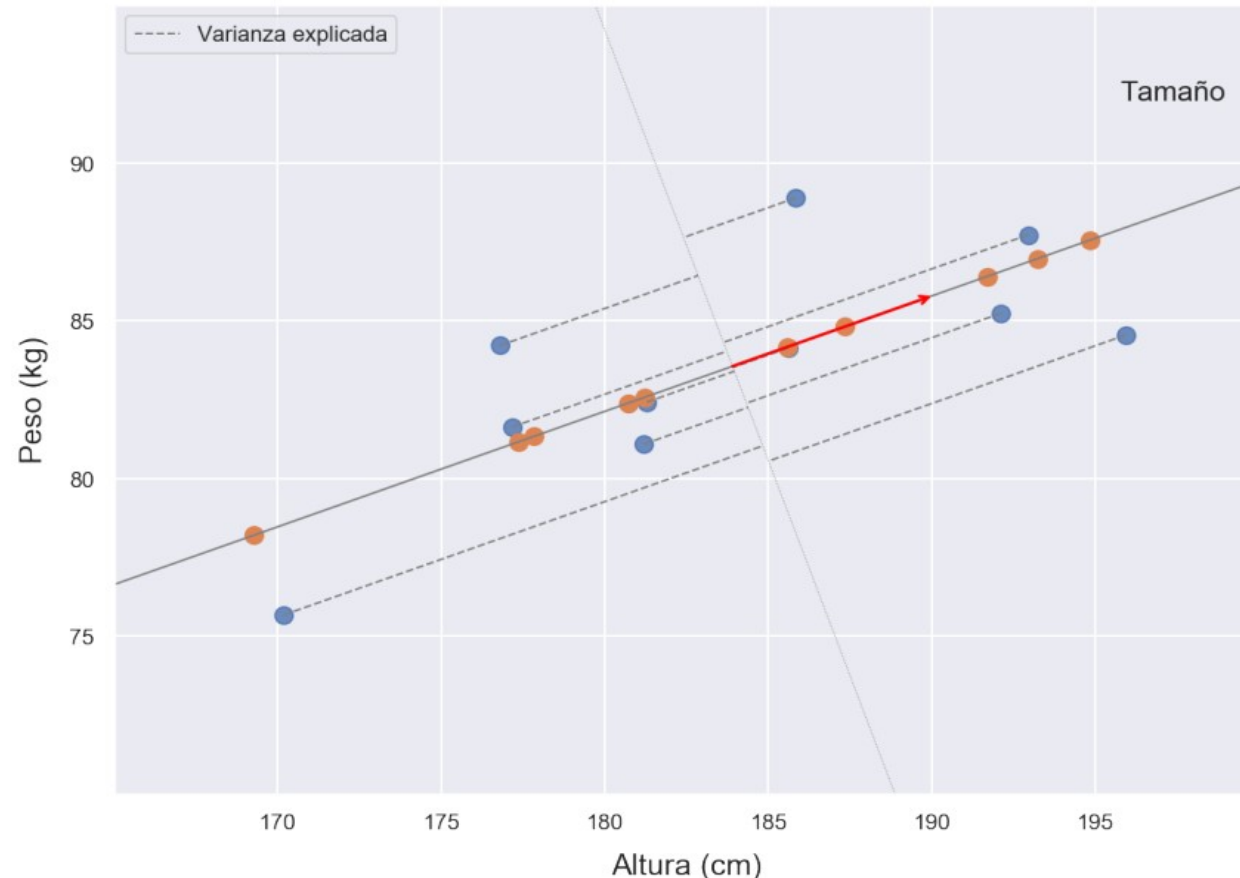
Podemos ver la representación final en una dimensión de las características de dos dimensiones originales. Representa la misma información

# 2. Datos fuertemente correlacionados

## Ejemplo




- La nueva característica **retiene** gran parte de la **varianza** presente en los datos originales.




# 2. Datos fuertemente correlacionados

## Ejemplo




- La nueva característica **no** retiene otra parte **varianza** presente en los datos originales.




# 2. Datos fuertemente correlacionados

## Ejemplo




- El objetivo es encontrar **la componente que maximice la varianza retenida (minimice la no retenida)**.

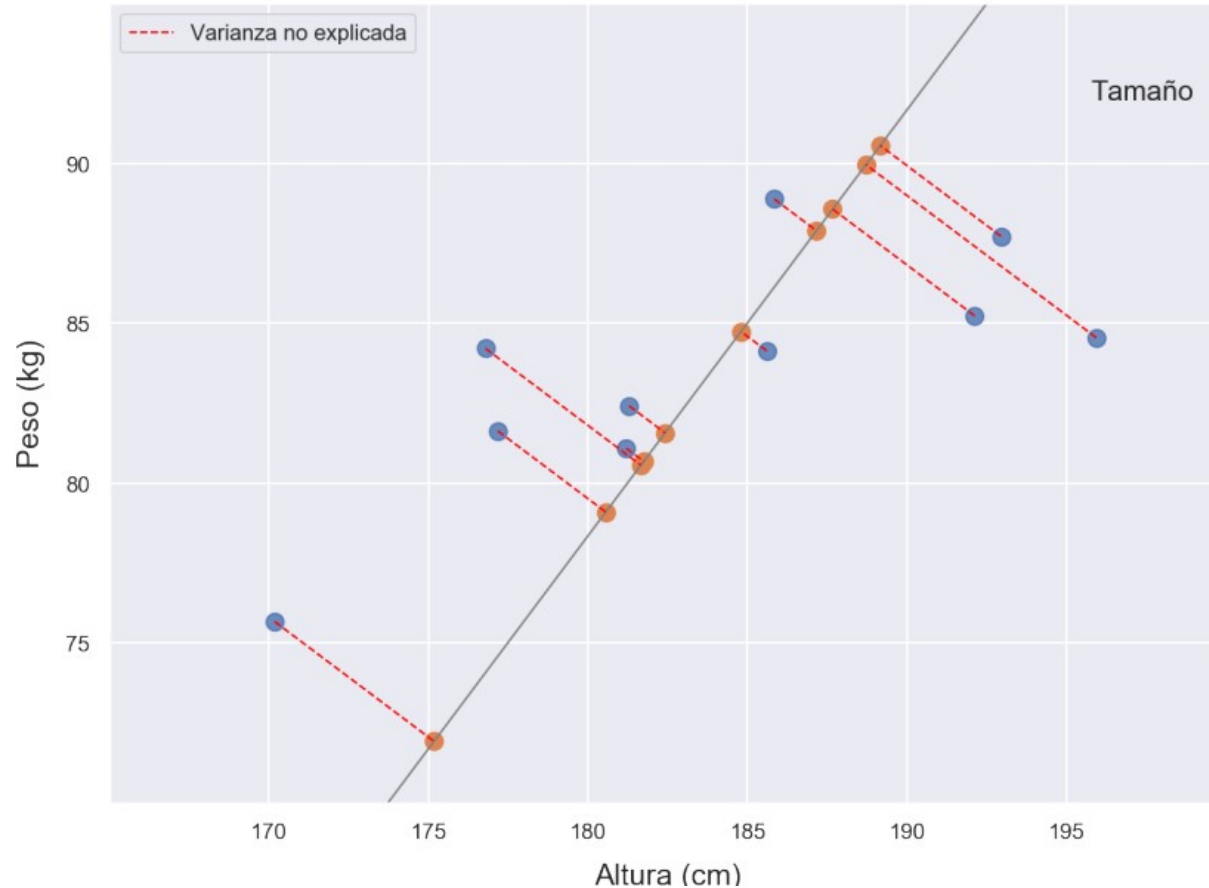


# 2. Datos fuertemente correlacionados

## Ejemplo




- El objetivo es encontrar **la componente que maximice la varianza retenida (minimice la no retenida)**.




La varianza (líneas en rojo) van disminuyendo

# 2. Datos fuertemente correlacionados

## Ejemplo




- El objetivo es encontrar **la componente que maximice la varianza retenida (minimice la no retenida)**.



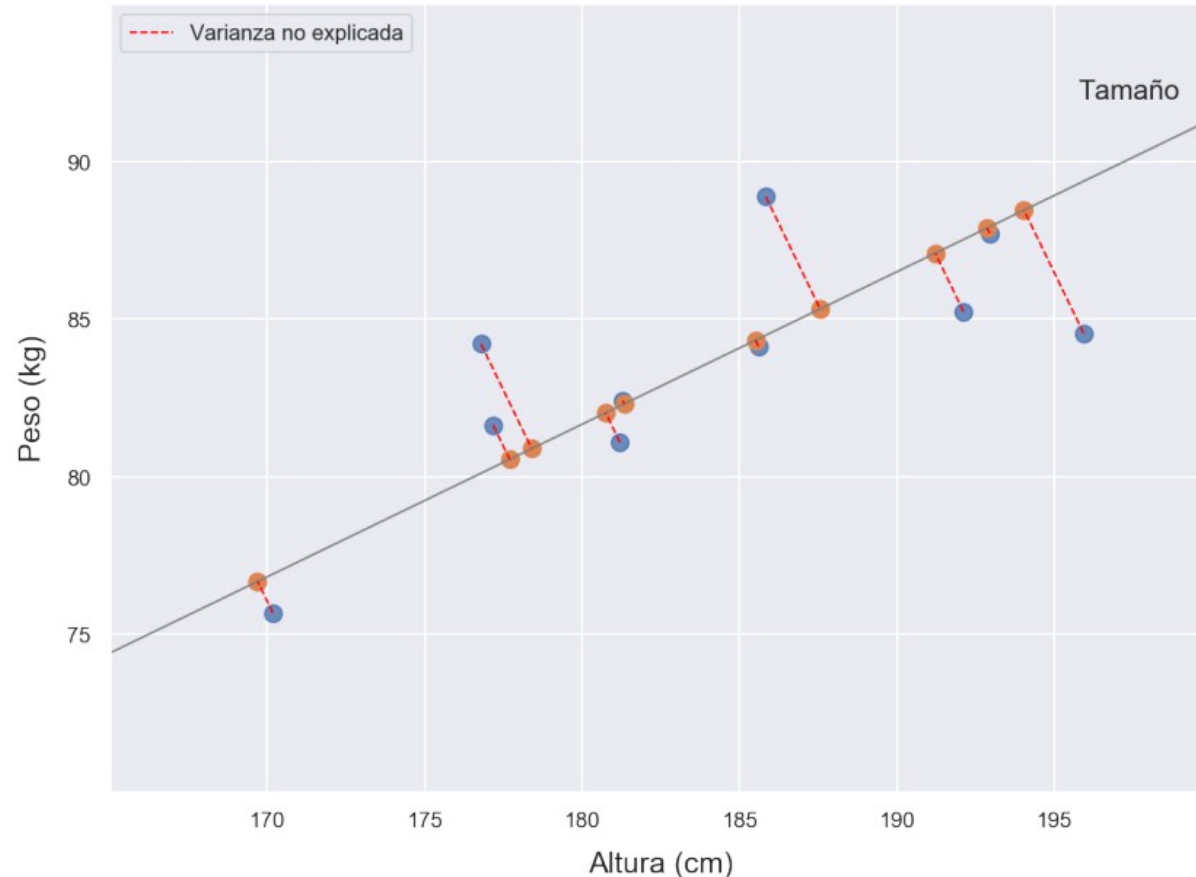
La varianza (líneas en rojo) van disminuyendo...

# 2. Datos fuertemente correlacionados

## Ejemplo




- El objetivo es encontrar **la componente que maximice la varianza retenida (minimice la no retenida)**.




La varianza (líneas en rojo) van disminuyendo...

# 2. Datos fuertemente correlacionados

## Ejemplo



- El objetivo es encontrar **la componente que maximice la varianza retenida (minimice la no retenida)**.




Hasta llegar a este.  
Se ha elegido este vector porque maximiza la varianza retenida y miniza la no retenida.  
Se le llama  
Componente Principal




# 2. Datos fuertemente correlacionados

## Ejemplo




- Se pueden definir componentes ortogonales a las existentes, tantas como características existen originalmente. Entre ellas, **retienen toda la varianza**.




# 2. Datos fuertemente correlacionados

## Ejemplo




- Se pueden definir componentes ortogonales a las existentes, tantas como características existen originalmente. Entre ellas, **retienen toda la varianza.**




Este vector tira otro componente que uniformiza a los datos originales.

# 2. Datos fuertemente correlacionados

## Ejemplo




- Se pueden definir componentes ortogonales a las existentes, tantas como características existen originalmente. Entre ellas, **retienen toda la varianza.**




La idea es tener  $k < n$ ,  
siendo  $k$  los  
componentes y  $n$   
características

# 2. Datos tridimensionales

## Ejemplo




- Este ejemplo (animado e interactivo) se puede ver [aquí](#).




# 2. Datos tridimensionales

## Ejemplo



- Este ejemplo (animado e interactivo) se puede ver [aquí](#).
  - La componente roja es la que tiene más varianza.
  - La componente roja y verde representa a los datos en dos dimensiones.






LAB CTIC UNI

# Principal Components Analysis


# 1. PCA



- Dado un conjunto de datos  $X \in R^{m \times n}$ , análisis de componentes principales consiste en obtener un conjunto de  $k$  componentes  $C \in R^{k \times n}$  que retengan la mayor parte de la varianza de los datos.
  - En el ejemplo anterior,  $k = 1$  y  $C \in R^{1 \times 2}$  ( $C$  es el vector que define la componente que representa el tamaño).
- PCA es útil cuando existen relaciones de **dependencia lineal** en los datos.
- Se utiliza para **reducir el número de características** original:
  - De cara a la exploración (características subyacentes)
  - Para almacenar los datos (con pérdidas) en menos espacio.
  - Para mejorar la eficiencia de algoritmos de aprendizaje supervisado.
  - Visualización (2 o 3 componentes).
  - etc.

# 2. PCA

## scikit-learn




|          | <b>Falafel</b> | <b>Kebab</b> | <b>Shushi</b> | <b>Cereales</b> |
|----------|----------------|--------------|---------------|-----------------|
| Alicia   | 10             | 1            | 2             | 7               |
| Bernardo | 7              | 2            | 1             | 10              |
| Carmen   | 2              | 9            | 7             | 3               |
| Diego    | 3              | 6            | 10            | 2               |
| Elena    | 1              | 8            | 8             | 3               |

$$n = 4$$
$$X \in \mathbb{R}^{5 \times 4}$$



## 2. PCA

scikit-learn




|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$n = 4$$
$$X \in \mathbb{R}^{5 \times 4}$$

- Si  $k < n$ , PCA devolvería las  $k$  primeras componentes ( $k$  primeras filas de  $C$ ).
- **Importante**: Los algoritmos devuelven las componentes ordenadas de **mayor a menor varianza retenida**.

# 2. PCA

## scikit-learn



|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$n = 4$$
$$X \in \mathbb{R}^{5 \times 4}$$

- Si  $k < n$ , PCA devolvería las  $k$  primeras componentes ( $k$  primeras filas de  $C$ ).
- **Importante**: Los algoritmos devuelven las componentes ordenadas de **mayor a menor varianza retenida**.


```
from sklearn.decomposition import PCA
pca = PCA(n_components=4)
pca.fit(X)
```

```
C = pca.components_
>>> C = [[ 0.52 -0.49 -0.54  0.46]
         [ 0.53 -0.46  0.5  -0.5 ]
         [ 0.47  0.56 -0.47 -0.49]
         [-0.48 -0.48 -0.49 -0.55]]
```

```
pca.explained_variance_ratio_
>>> [0.9  0.08 0.02 0. ]
```

# 3. Proyección de los datos

## Dos Componentes



- Dadas la matriz de datos  $X \in \mathbb{R}^{m \times n}$ , y las componentes  $C \in \mathbb{R}^{k \times k}$ , la transformación consiste en obtener una nueva matriz de datos  $X_{(pc)} \in \mathbb{R}^{m \times k}$ . Es decir, con  $k$  columnas.

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$n = 4, k = 2$$

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}$$


$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

✎ La proyección se calcula como  $X_{(pc)} = (X - \bar{x})C^T$

```
X_pc = pca.transform(X)
```

```
>>> X_pc = [[ 7.67  2.01]
             [ 7.55 -2.06]
             ...]
```

$$X_{(pc)} = (X - \bar{x})C^T = \begin{bmatrix} 5.4 & -4.2 & -3.6 & 2 \\ 2.4 & -3.2 & -4.6 & 5 \\ -2.6 & 3.8 & 1.4 & -2 \\ -1.6 & 0.8 & 4.4 & -3 \\ -3.6 & 2.8 & 2.4 & -2 \end{bmatrix} \begin{bmatrix} 0.52 & 0.53 \\ -0.49 & -0.46 \\ -0.54 & 0.5 \\ 0.46 & -0.5 \end{bmatrix} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$



# 3. Proyección de los datos

## Dos Componentes

- Dadas la matriz de datos  $X \in \mathbb{R}^{m \times n}$ , y las componentes  $C \in \mathbb{R}^{k \times k}$ , la transformación consiste en obtener una nueva matriz de datos  $X_{(pc)} \in \mathbb{R}^{m \times k}$ . Es decir, con  $k$  columnas.

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$n = 4, k = 2$$

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}$$


$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

✎ La proyección se calcula como  $X_{(pc)} = (X - \bar{x})C^T$

```
x_pc = pca.transform(X)
>>> x_pc = [[ 7.67  2.01]
             [ 7.55 -2.06]
             ...]
```

$$X_{(pc)} = (X - \bar{x})C^T = \begin{bmatrix} 5.4 & -4.2 & -3.6 & 2 \\ 2.4 & -3.2 & -4.6 & 5 \\ -2.6 & 3.8 & 1.4 & -2 \\ -1.6 & 0.8 & 4.4 & -3 \\ -3.6 & 2.8 & 2.4 & -2 \end{bmatrix} \begin{bmatrix} 0.52 & 0.53 \\ -0.49 & -0.46 \\ -0.54 & 0.5 \\ 0.46 & -0.5 \end{bmatrix} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

Fijaros que tenemos dos grupos, por ejemplo a Alicia le gusta Falafel y Cereales y no le gusta kebab y shushi



# 3. Proyección de los datos

## Dos Componentes

- Dadas la matriz de datos  $X \in \mathbb{R}^{m \times n}$ , y las componentes  $C \in \mathbb{R}^{k \times k}$ , la transformación consiste en obtener una nueva matriz de datos  $X_{(pc)} \in \mathbb{R}^{m \times k}$ . Es decir, con  $k$  columnas.

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$n = 4, k = 2$$

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 2}$$

$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

C1 es característica 1 y 4 positivo y (comida vegetariana) y 2 y 3 negativos (no vegetariana).


Representa el gusto por la comida vegetariana

✎ La proyección se calcula como  $X_{(pc)} = (X - \bar{x})C^T$

```
X_pc = pca.transform(X)
```

```
>>> X_pc = [[ 7.67  2.01]
             [ 7.55 -2.06]
             ...]
```

$$X_{(pc)} = (X - \bar{x})C^T = \begin{bmatrix} 5.4 & -4.2 & -3.6 & 2 \\ 2.4 & -3.2 & -4.6 & 5 \\ -2.6 & 3.8 & 1.4 & -2 \\ -1.6 & 0.8 & 4.4 & -3 \\ -3.6 & 2.8 & 2.4 & -2 \end{bmatrix} \begin{bmatrix} 0.52 & 0.53 \\ -0.49 & -0.46 \\ -0.54 & 0.5 \\ 0.46 & -0.5 \end{bmatrix} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$



# 3. Proyección de los datos

## Dos Componentes

- Dadas la matriz de datos  $X \in \mathbb{R}^{m \times n}$ , y las componentes  $C \in \mathbb{R}^{k \times k}$ , la transformación consiste en obtener una nueva matriz de datos  $X_{(pc)} \in \mathbb{R}^{m \times k}$ . Es decir, con  $k$  columnas.

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$n = 4, k = 2$$

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 2}$$

$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

C2 es característica 1 y 3 positivo (comida semi-sana) y 2 y 4 negativos (no sana).  
Representa (en cierto modo) el gusto por la comida sana


✎ La proyección se calcula como  $X_{(pc)} = (X - \bar{x})C^T$

```
X_pc = pca.transform(X)
```

```
>>> X_pc = [[ 7.67  2.01]
             [ 7.55 -2.06]
             ...]
```

$$X_{(pc)} = (X - \bar{x})C^T = \begin{bmatrix} 5.4 & -4.2 & -3.6 & 2 \\ 2.4 & -3.2 & -4.6 & 5 \\ -2.6 & 3.8 & 1.4 & -2 \\ -1.6 & 0.8 & 4.4 & -3 \\ -3.6 & 2.8 & 2.4 & -2 \end{bmatrix} \begin{bmatrix} 0.52 & 0.53 \\ -0.49 & -0.46 \\ -0.54 & 0.5 \\ 0.46 & -0.5 \end{bmatrix} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$


# 4. Visualización




|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$X_{(pc)} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

- La reducción a dos (o 3) componentes permite visualizar datos multidimensionales.
- Podemos ver en esta representación los gustos de cada instancia según los componentes reconstruidos en 2D.





# 5. Interpretación

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}, X_{(pc)} \in \mathbb{R}^{5 \times 2}$$


$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

$$X_{(pc)} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

- Los elementos (*loadings*) de una componente reflejan la relación con la variable correspondiente. En algunos casos, es útil la interpretación.
  - Ej: la primera componente refleja la preferencia por comida vegetariana ( $X_1$  y  $X_4$ ).
- Cada elemento  $x^{(i)}$  se puede construir como una combinación lineal de las  $k$  componentes  $C$ .  $x_{(pc)}^{(i)}$  representa el peso de cada componente, y  $x_{(app)}^{(i)}$  su reconstrucción. Ejemplo:

$$x_{app}^{(1)} = \bar{x} + 7.67 \cdot \begin{bmatrix} 0.52 \\ -0.49 \\ -0.54 \\ 0.46 \end{bmatrix} + 2.01 \cdot \begin{bmatrix} 0.53 \\ -0.46 \\ 0.5 \\ -0.5 \end{bmatrix} = \begin{bmatrix} 9.62 \\ 0.54 \\ 2.48 \\ 7.5 \end{bmatrix}$$





# 5. Interpretación

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}, X_{(pc)} \in \mathbb{R}^{5 \times 2}$$

$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$


$$X_{(pc)} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

$X_{PC1}$  vegetal

$X_{PC2}$  Sano

- Los elementos (*loadings*) de una componente reflejan la relación con la variable correspondiente. En algunos casos, es útil la interpretación.
  - Ej: la primera componente refleja la preferencia por comida vegetariana ( $X_1$  y  $X_4$ ).
- Cada elemento  $x^{(i)}$  se puede construir como una combinación lineal de las  $k$  componentes  $C$ .  $x_{(pc)}^{(i)}$  representa el peso de cada componente, y  $x_{(app)}^{(i)}$  su reconstrucción. Ejemplo:

$$x_{app}^{(1)} = \bar{x} + 7.67 \cdot \begin{bmatrix} 0.52 \\ -0.49 \\ -0.54 \\ 0.46 \end{bmatrix} + 2.01 \cdot \begin{bmatrix} 0.53 \\ -0.46 \\ 0.5 \\ -0.5 \end{bmatrix} = \begin{bmatrix} 9.62 \\ 0.54 \\ 2.48 \\ 7.5 \end{bmatrix}$$



# 5. Interpretación

|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}, X_{(pc)} \in \mathbb{R}^{5 \times 2}$$

$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$


$$X_{(pc)} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

- Los elementos (*loadings*) de una componente reflejan la relación con la variable correspondiente. En algunos casos, es útil la interpretación.
  - Ej: la primera componente refleja la preferencia por comida vegetariana ( $X_1$  y  $X_4$ ).
- Cada elemento  $x^{(i)}$  se puede construir como una combinación lineal de las  $k$  componentes  $C$ .  $x_{(pc)}^{(i)}$  representa el peso de cada componente, y  $x_{(app)}^{(i)}$  su reconstrucción. Ejemplo:

$$x_{app}^{(1)} = \bar{x} + 7.67 \cdot \begin{bmatrix} 0.52 \\ -0.49 \\ -0.54 \\ 0.46 \end{bmatrix} + 2.01 \cdot \begin{bmatrix} 0.53 \\ -0.46 \\ 0.5 \\ -0.5 \end{bmatrix} = \begin{bmatrix} 9.62 \\ 0.54 \\ 2.48 \\ 7.5 \end{bmatrix}$$

No salen los datos exactos porque se han utilizado dos componentes y queda una poca varianza sin explicar (pierde información) pero son muy aproximados

# 6. Reconstrucción a partir de las componentes



|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}, X_{(pc)} \in \mathbb{R}^{5 \times 2}$$

$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

$$X_{(pc)} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

✎ La reconstrucción,  $X_{(app)} \in \mathbb{R}^{5 \times 4}$  se obtiene como:


$$X_{(app)} = \bar{x} + X_{(pc)} C$$

$$X_{(app)} = \bar{x} + \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix} \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix} = \begin{bmatrix} 9.6 & 0.5 & 2.5 & 7.5 \\ 7.4 & 2.5 & 0.5 & 9.5 \\ 1.3 & 8.2 & 7.5 & 3.5 \\ 3.4 & 6.4 & 9.5 & 1.5 \\ 1.3 & 8.3 & 8.0 & 3.0 \end{bmatrix}$$

```
X_app = pca.inverse_transform(X_pc)
```

```
>>> X_app = [[9.62 0.54 2.48 7.5 ]
              [7.4  2.49 0.51 9.49]
              ...]
```

# 6. Reconstrucción a partir de las componentes



|          | Falafel | Kebab | Shushi | Cereales |
|----------|---------|-------|--------|----------|
| Alicia   | 10      | 1     | 2      | 7        |
| Bernardo | 7       | 2     | 1      | 10       |
| Carmen   | 2       | 9     | 7      | 3        |
| Diego    | 3       | 6     | 10     | 2        |
| Elena    | 1       | 8     | 8      | 3        |

$$X \in \mathbb{R}^{5 \times 4}, C \in \mathbb{R}^{2 \times 4}, X_{(pc)} \in \mathbb{R}^{5 \times 2}$$

$$C = \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix}$$

$$X_{(pc)} = \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix}$$

✎ La reconstrucción,  $X_{(app)} \in \mathbb{R}^{5 \times 4}$  se obtiene como:

$$X_{(app)} = \bar{x} + X_{(pc)} C$$

```
X_app = pca.inverse_transform(X_pc)
```


```
>>> X_app = [[9.62 0.54 2.48 7.5 ]
              [7.4  2.49 0.51 9.49]
              ...]
```

$$X_{(app)} = \bar{x} + \begin{bmatrix} 7.67 & 2.01 \\ 7.55 & -2.06 \\ -4.85 & -1.44 \\ -4.95 & 2.49 \\ -5.42 & -1. \end{bmatrix} \begin{bmatrix} 0.52 & -0.49 & -0.54 & 0.46 \\ 0.53 & -0.46 & 0.5 & -0.5 \end{bmatrix} = \begin{bmatrix} 9.6 & 0.5 & 2.5 & 7.5 \\ 7.4 & 2.5 & 0.5 & 9.5 \\ 1.3 & 8.2 & 7.5 & 3.5 \\ 3.4 & 6.4 & 9.5 & 1.5 \\ 1.3 & 8.3 & 8.0 & 3.0 \end{bmatrix}$$



LAB CTIC  UNI

## Varianza y selección de $k$



# 1. Varianza

- La varianza de los datos se computa como la suma de las varianzas de cada variable:

$$\text{var}(X) = \sum_{j=1}^n \text{var}(X_j)$$

- La varianza **explicada** por las componentes se calcula como las varianzas las características correspondientes:
  - Las componentes principales corresponden con autovectores de la matriz de covarianza de los datos. Cada  $X_{(pc),j}$  es el autovalor correspondiente al vector  $j$ .

$$\text{var}(X_{(pc)}) = \sum_{j=1}^k \text{var}(X_{(pc),j})$$


- Se cumple que, si  $k = n \rightarrow \text{var}(X) = \text{var}(X_{(pc)})$
- Interesa la fracción de varianza que explica cada componente  $C_j, \frac{\text{var}(X_{(pc),j})}{\text{var}(X_{(pc)})}$

```
pca.explained_variance_  
>>> [48.34709495  4.38266532]
```

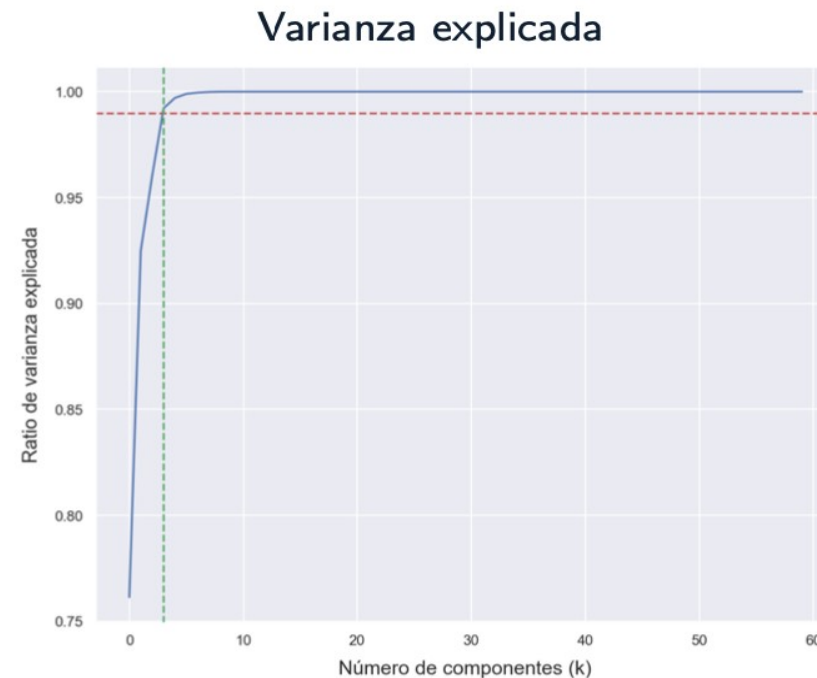
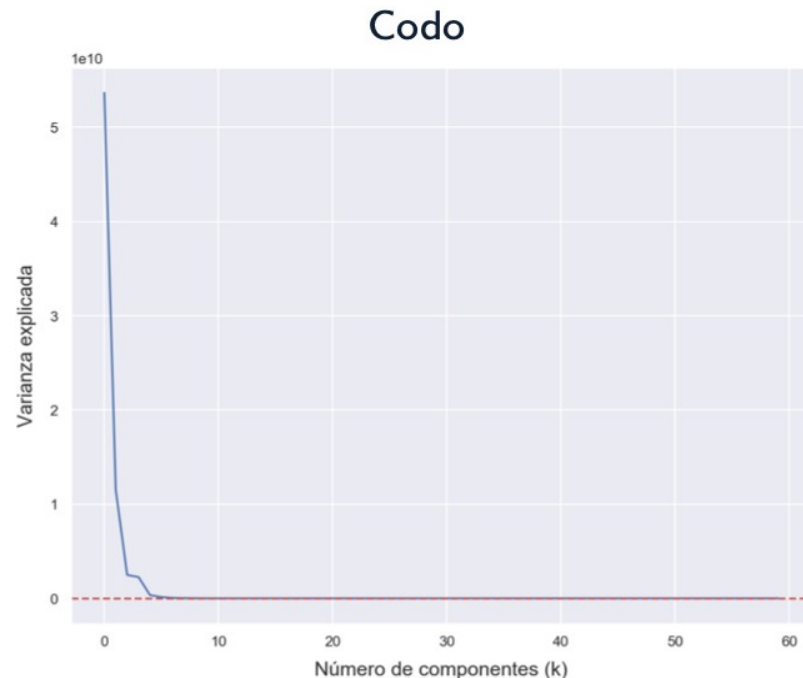
```
pca.explained_variance_ratio_  
>>> [0.89864489 0.08146218]
```

```
pca.explained_variance_ratio_  
>>> [0.89864489 0.98010707]
```


## 2. Elección de $k$



- El número de componentes,  $k$ , determina la precisión con la que las componentes representan los datos originales (la varianza explicada).
- Existen dos métodos principales para seleccionar el valor de  $k$ :



- Un tercer método, denominado **Kaiser-Guttman** consiste en escoger las componentes que expliquen una varianza mayor que uno (con datos estandarizados).




# Smart City

LAB CTIC  UNI

**PCA como algoritmos de aprendizaje  
no supervisado**





# 1. Hipótesis y objetivos

## 👉 Nota

Es **necesario** que los datos estén normalizados a media cero , es decir,  $\bar{x} = [0, 0, \dots]$ . Se recomienda también que las varianzas sean uno.

- Dados el conjunto de datos  $X$ , y el conjunto de componentes  $C$ :

$$X_{(pc)} = XC^T \quad X_{(app)} = X_{(pc)} C$$

- Por tanto, la reconstrucción de los datos puede expresarse como:

$$X_{(app)} = (XC^T)C$$

- Se define la función de hipótesis como:

$$h_{\theta}(x) = xC^T C, \quad x \in \mathbb{R}^n, \theta = \{C \in \mathbb{R}^{k \times n}\}$$


- El coste se expresa como:

$$J(\theta) = \|h_{\theta}(x) - x\|^2 = \|xC^T C - x\|^2$$

- Por tanto, el objetivo es:

$$\underset{C}{\operatorname{argmin}} \sum_{i=1}^m \|xC^T C - x\|^2$$

Que según los componentes la pérdida de información (varianza) sea mínima



## 2. Algoritmos

- La mayoría de las implementaciones de PCA se basan en descomposición en valores singulares (SVD).

- Una matriz  $X \in \mathbb{R}^{m \times n}$  puede descomponerse como:

$$X = UsV^T, \quad U \in \mathbb{R}^{m \times n}, s \in \mathbb{R}^n, V \in \mathbb{R}^{n \times N}$$

- **Método 1:** dados  $X$  y  $k$ , se pueden obtener  $C$  y  $X_{(pc)}$  como:

$$C = V_{:,1:k}^T \quad X_{(pc)} = U_{:,1:k} s_{:k}$$

- **Método 2:** dados  $X$  y  $k$ , se calcula la matriz de covarianzas de  $X$  como:


$$\Sigma = \frac{1}{m} X^T X$$

Mediante SVD se descompone  $\Sigma = UsV^T$ , de modo que puede obtenerse  $C$  como:

$$C = U_{:,1:k}$$

$C$  está formada por los  $k$  autovectores (*eigenvectors*) de la matriz de covarianzas con mayor autovalor (*eigenvalue*).

**¡GRACIAS!**



**Smart City**

LAB CTIC  UNI

**Dr. Manuel Castillo-Cara**  
**Machine Learning con Python**  
**Web: [www.smartcityperu.org](http://www.smartcityperu.org)**