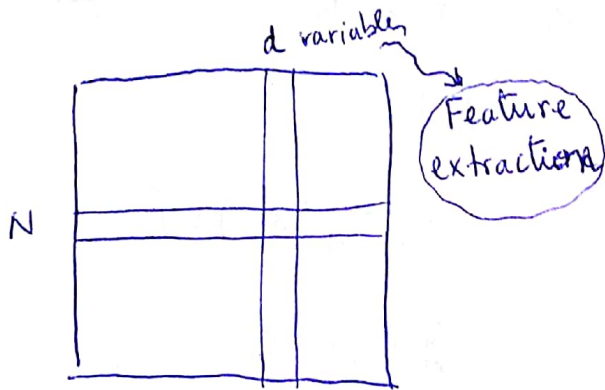



## ② Reducción de dimensión



- La probabilidad de sobreajuste se incrementa con la dimensión
- Visualización de datos.
- Preservar la información relevante en los datos

### Métodos

#### (1) Análisis de componentes principales (ACP/PCA)



→ Para PCA: "información relevante" es dispersión

- Tenemos una muestra de datos  $\{x_1, x_2, \dots, x_N\}$ ,  $x_n \in \mathbb{R}^d$ , <sup>→ son vectores, puntos d-dimensionales</sup> que provienen de un vector aleatorio  $X = (X_1, \dots, X_d)^T$ , con media  $\mu$  y matriz de covarianza  $\Sigma \rightarrow \Sigma = (\sigma_{ij}^2)$ ,  $\text{Cov}(X_i, X_j) = \sigma_{ij}^2$ ,  $\text{Var}(X_i) = \sigma_{ii}^2 =: \sigma_i^2$
- Consideramos el problema de encontrar un nuevo sistema de coordenadas (vector de variables).  $Y = (Y_1, \dots, Y_d)^T$ 
  - 1)  $\text{Cov}(Y_i, Y_j) = 0$ ,  $i \neq j$
  - 2)  $\text{Var}(Y_1) > \text{Var}(Y_2) > \dots > \text{Var}(Y_d)$
  - 3)  $\sum_{i=1}^d \text{Var}(X_i) = \sum_{i=1}^d \text{Var}(Y_i)$

} condiciones

La solución más simple es que las  $Y_j$  sean c.l. de las  $X_i$   
 ↳ combinación lineal

$$Y_j = a_j^T X$$

Imponemos la normalización  $\|a_j\| = 1 \Leftrightarrow \|a_j\|^2 = 1$   
 ↳ lo mismo (para simplificar)

Objetivo:  $a_1$  ha de maximizar la varianza de  $Y_1$  sujeto a  $\|a_1\|^2 = 1$

$$\bullet \text{Var}(Y_1) = \text{Var}(a_1^T X) = a_1^T \text{Var}(X) a_1 = a_1^T \Sigma a_1$$

vector de números       $\Sigma$       vector matriz

Solución a maximizar  $a_1^T \Sigma a_1$  sujeto a  $\|a_1\|^2 = 1 \rightsquigarrow \|a_1\|^2 - 1 = 0$

$$L(a_1) = a_1^T \Sigma a_1 - \lambda (\|a_1\|^2 - 1) \rightarrow \text{Función Lagrangiana.}$$

$$\frac{\partial L}{\partial a_1} = 2 \Sigma a_1 - 2 \lambda a_1 = 0 \Rightarrow \Sigma \cdot a_1 = \lambda a_1$$

$x \cdot y = (\cdot)(\cdot)$   
 $x^T y = (\cdot)(\cdot)$

→ encontrar un vector propio  $a_1$  de valores propios  $\lambda$ . ↳ mirar!!

¡Ya está!  $\lambda_{(1)} > \lambda_{(2)} > \dots > \lambda_{(d)} > 0$   
 ↳ propiedad matriz covarianza  $\Sigma$

$$\rightarrow \text{maxim. } \text{Var}(Y_1) = a_1^T \Sigma a_1 = a_1^T (\lambda a_1) = \lambda (a_1^T a_1) = \lambda \underbrace{\|a_1\|^2}_1 = \lambda \Rightarrow$$

⇒ elijo como  $\lambda = \lambda_{(1)} \Rightarrow a_1$  es su vector propio correspondiente.

• Resulta que  $a_2$  se encuentra igual, con la condición adicional

$$\boxed{a_2^T a_1 = 0} \rightarrow \text{perpendiculares (como las componentes)}$$

→  $a_2$  es el vector propio de  $\Sigma$  con valor propio  $\lambda_{(2)}$

• Resultados

... y así  $a_3, a_4, \dots$

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1d} \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \end{pmatrix} \quad Y = A^T X$$

↳ hay que coger  $m$  componentes principales

Si nos quedamos con  $m (\leq d)$  de los C.P. (componentes principales)

$$\frac{\sum_{i=1}^m \lambda_{(i)}}{\sum_{i=1}^d \lambda_{(i)}} \times 100\% \rightarrow \text{el \% de varianza retenida.}$$

¿Qué porcentaje nos interesa mantener?

- ⊕ Si el objetivo es reducir la dimensión (eliminando ruido), un criterio es del 90% de la varianza retenida.
- ⊗ Si el objetivo es visualizar,  $m = 2$  ó  $3$

### Propiedades

1) La matriz de covarianza de las  $Y$  es:

$$\Delta = \text{diag}(\lambda_{(1)}, \lambda_{(2)}, \dots, \lambda_{(d)})$$


2)  $\text{Var}(Y_1) > \text{Var}(Y_2) > \dots > \text{Var}(Y_d)$

$$\lambda_{(1)} > \lambda_{(2)} > \dots > \lambda_{(d)}$$

traza  $\Rightarrow$  suma de los elementos de la diagonal

$$3) \sum_{i=1}^d \text{Var}(X_i) = \sum_{i=1}^d \lambda_{(i)} = \text{Tr}(\Sigma) = \sum_{i=1}^d \text{Var}(X_i)$$

traza matriz = suma valores propios



## (2) Analisis discriminante de Fischer (ADF/FDA)

$$D = \{(x_1, t_1), \dots, (x_N, t_N)\}, \quad x_n \in \mathbb{R}^d, \quad t_n \in \{1, 2\}$$

$N_1, N_2$  observaciones de cada clase,  $N_1 + N_2 = N$

$$m_1 = \frac{1}{N_1} \sum_{n \in C_1} x_n; \quad m_2 = \frac{1}{N_2} \sum_{n \in C_2} x_n$$

$$\delta = |\mu_1 - \mu_2| = |w^T m_1 - w^T m_2| = |w^T (m_1 - m_2)|$$

