

## **PCA ROBUSTO Y EXTENSIONES DE PCA**

ALAN REYES-FIGUEROA

INTRODUCCIÓN A LA CIENCIA DE DATOS

(AULA 12) 15.FEBRERO.2021

# Métodos robustos para PCA

Idea: Evitar que ciertas observaciones tengan mucha influencia en la estimación de las componentes (*e.g.* datos atípicos o datos extremos).

Usualmente hay dos enfoques:

- limitar el efecto de datos típicos
  - ponderar los datos
  - transformar los datos
- eliminar datos atípicos y convertirlos en estimaciones (*e.g.* método masking).

# PCA Ponderado

Ponderamos los datos. En lugar de calcular  $\mu$  y  $\Sigma$  en la forma usual

$$\mu = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i, \quad \Sigma = \frac{1}{n} \mathbb{X}_c^T \mathbb{X}_c = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^T,$$

calculamos la media ponderada de los datos

$$\mu = \frac{1}{\sum_i w_i} \sum_{i=1}^n w_i \mathbf{x}_i,$$

y la matriz de covarianza ponderada

$$\Sigma = \frac{1}{\sum_i w_i} \sum_{i=1}^n w_i (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^T.$$

Si conociéramos  $\Sigma$ , podemos medir cuán lejos está una observación  $\mathbf{x}_i$  del centro de la distribución.

## Definición

La **distancia de Mahalanobis** de una distribución  $\mathcal{N}(\mu, \Sigma)$  se calcula como

$$d_{Mah}(\mathbf{x}_i, \mu) = (\mathbf{x}_i - \mu)^T \Sigma^{-1} (\mathbf{x}_i - \mu).$$

Entonces, esto genera un algoritmo iterativo en dos pasos:

1. Si conocemos  $\Sigma$ , calculamos las  $d_i = d_{Mah}(\mathbf{x}_i, \mu)$ , y podemos definir pesos  $w_i = f(d_i)$ , donde  $f$  es una función decreciente.
2. Con los  $w_i$ , podemos re-estimar  $\Sigma$  como

$$\Sigma = \frac{1}{\sum_i w_i} \sum_{i=1}^n w_i (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^T.$$

Se puede mostrar que bajo ciertos supuestos, este algoritmo converge.

# Spherical PCA

Debida a S. Marron.

Transformamos los datos. Para ello, se toma una hiperesfera en  $\mathbb{R}^d$ , centrada en la mediana robusta  $\mu$  de los datos, y proyectamos cada datos  $\mathbf{x}_i$  sobre dicha esfera.

Equivalente a normalizar la distancia a  $\mu$  no influye.

Tomamos todos los datos, pero limitamos el efecto sobre la estimación.

Para ello es necesario definir la mediana para datos multidimensionales. Una posible solución que la mediana  $\mu$  satisface

$$\sum_{i=1}^n \frac{\mathbf{x}_i - \mu}{\|\mathbf{x}_i - \mu\|} = \mathbf{0}.$$

# Minimum Volume Ellipsoid

Debida a P. Rousseau.

Localizamos y eliminamos outliers. Para ello, buscamos el elipsoide de volumen mínimo que contenga cierto porcentaje  $h\%$  de los datos. Luego estimamos  $\Sigma$  con sólo esta muestra.

Recordemos que en los elipsoides  $\{\mathbf{x} : \mathbf{x}^T \mathbf{A} \mathbf{x} = c\}$ , con  $A$  simétrica y positiva definida, el volumen es proporcional a  $\det A$ .

Pregunta: ¿Cómo hallar el subconjunto  $H \subset \mathbb{R}^d$  de las  $h\%$  observaciones cuya matriz de covarianza tiene determinante mínimo?

# Minimum Volume Ellipsoid

## Propiedad

Sean  $\mu$  y  $\Sigma$  estimadas con un subconjunto  $H$  de  $h\%$  observaciones. Definamos  $H_1$  subconjunto las  $h\%$  observaciones más cercanas a  $\mu$  en la distancia de Mahalanobis de  $\Sigma$ . Entonces, para  $\Sigma_1$  estimada con  $H_1$

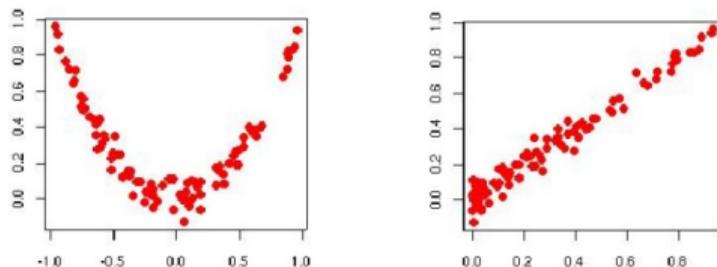
$$\det \Sigma_1 \leq \det \Sigma.$$

## Algoritmo:

- 1.) Inicio: Dados  $\mu^0$  y  $\Sigma^0$
- 2.) Repetir para  $i = 1, 2, 3, \dots$  (hasta cierto criterio de paro):
  - Calcular  $S = \{h\% \text{ de las observaciones más cercanas a } \mu^{i-1}\}$
  - Estimar  $\mu^i$  y  $\Sigma^i$  con base en  $S$ .

$$A = \sum_i \lambda_i \mathbf{u}_i \mathbf{u}_i^T \Rightarrow \mathbf{x}^T A \mathbf{x} = \sum_i (\sigma_i \mathbf{x}^T \mathbf{u}_i) (\sigma_i \mathbf{u}_i^T \mathbf{x}) = \sum_i (\sigma_i \langle \mathbf{x}, \mathbf{u}_i \rangle)^2.$$

# Extensiones no-lineales de PCA



Transformar los datos (similar a regresión no-lineal!)

E.g., definimos  $\Phi(\mathbf{x}) = \Phi(x_1, x_2) = (x_1^2, x_2)$ , y aplicamos PCA a los  $\{\Phi(\mathbf{x}_i)\}$ .

- Antes: En escalamiento multidimensional,  
 $P_u(\mathbf{x}) = \sum_i \alpha_i \langle \mathbf{x}_i, \mathbf{x} \rangle$ , donde  $\alpha_i$  depende sólo de  $\mathbb{X}\mathbb{X}^T = [\langle \mathbf{x}_i, \mathbf{x}_j \rangle]_{i,j}$ .
- Ahora: Transformamos  $\mathbf{x}$  a  $\Phi(\mathbf{x})$ , y definimos  $K_\Phi(\mathbf{x}, \mathbf{y}) = \langle \Phi(\mathbf{x}), \Phi(\mathbf{y}) \rangle$ .  
 $P_u^\Phi(\mathbf{x}) = P_u(\Phi(\mathbf{x})) = \sum_i \alpha_i K_\Phi(\mathbf{x}_i, \mathbf{x})$ ,  $\alpha_i$  depende de  $\mathbb{K} = [K_\Phi(\mathbf{x}_i, \mathbf{x}_j)]_{i,j}$ .

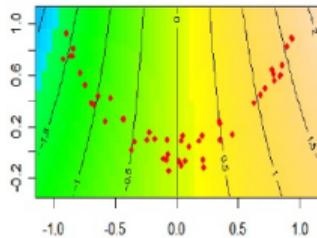
## Definición

A la función  $K_\Phi$  se le llama una **función kernel** inducida por  $\Phi$ .

Típicamente,  $K_\Phi$  debe ser simétrica y tal que  $K_\Phi(\mathbf{x}, \mathbf{x}) \geq 0$ . Además, se requiere que la matriz  $\mathbb{K} = [K_\Phi(\mathbf{x}_i, \mathbf{x}_j)]_{i,j}$ , sea definida positiva.

En el método de Kernel PCA, definimos explícitamente  $K(\mathbf{x}_i, \mathbf{x}_j)$ , y sólo implícitamente  $\Phi$ .

Problema: nuestra intuición no es buena para pensar en términos de productos puntos (contrario a distancias).



Ejemplo 1: Sea  $\mathbf{z} = (z_1, z_2) \in \mathbb{R}^2$ . Consideremos la transformación  $\Phi : \mathbb{R}^2 \rightarrow \mathbb{R}^6$  dada por

$$\Phi(\mathbf{z}) = (1, \sqrt{2}z_1, \sqrt{2}z_2, z_1^2, \sqrt{2}z_1z_2, z_2^2).$$

Observe que

$$\begin{aligned} K_\Phi(\mathbf{x}_1, \mathbf{x}_2) &= \langle \Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2) \rangle \\ &= \langle (1, \sqrt{2}x_1, \sqrt{2}y_1, x_1^2, \sqrt{2}x_1y_1, y_1^2), (1, \sqrt{2}x_2, \sqrt{2}y_2, x_2^2, \sqrt{2}x_2y_2, y_2^2) \rangle \\ &= 1 + 2x_1x_2 + 2y_1y_2 + x_1^2x_2^2 + 2x_1x_2y_1y_2 + y_1^2y_2^2 \\ &= (1 + x_1x_2 + y_1y_2)^2 = (1 + \langle (x_1, y_1), (x_2, y_2) \rangle)^2 \\ &= (1 + \langle \mathbf{x}_1, \mathbf{x}_2 \rangle)^2. \end{aligned}$$

En general podemos definir  $K_\Phi(\mathbf{x}, \mathbf{y}) = (1 + \langle \mathbf{x}, \mathbf{y} \rangle)^p$ .

Ejemplo 2: cuando  $\mathbf{x}$  no tiene una representación vectorial (natural).

Sean  $\mathbf{x}$  y  $\mathbf{y}$  dos cadenas de longitud  $d$  sobre el alfabeto  $\mathcal{A}$ , i.e.  $\mathbf{x}, \mathbf{y} \in \mathcal{A}^d$ .

Definimos  $\Phi(\mathbf{x}) = (\Phi_s(\mathbf{x}))_{s \in \mathcal{A}^d}$ , donde  $\Phi_s(\mathbf{x})$  denota el número de veces que la subcadena  $s$  aparece en  $\mathbf{x}$ .

Eso es más fácil de calcular que  $\langle \Phi(\mathbf{x}), \Phi(\mathbf{y}) \rangle$  directamente:

$$\langle \Phi(\mathbf{x}), \Phi(\mathbf{y}) \rangle = \sum_{s \in S(\mathbf{x}, \mathbf{y})} \Phi_s(\mathbf{x}) \Phi_s(\mathbf{y}),$$

con  $S(\mathbf{x}, \mathbf{y})$  el conjunto de subcadenas comunes de  $\mathbf{x}$  y  $\mathbf{y}$ .

Ejemplo 3: cuando  $\mathbf{x}$  no tiene una representación vectorial (natural).

Sea  $\mathbb{P}()$  una distribución de probabilidad. Definimos

$$K_{\Phi}(\mathbf{x}, \mathbf{y}) = \mathbb{P}(\mathbf{x}) \mathbb{P}(\mathbf{y}).$$

Interpretación usando la norma inducida por  $\|\cdot\|$ :

$$\|\Phi(\mathbf{x}) - \Phi(\mathbf{y})\|^2 = K_{\Phi}(\mathbf{x}, \mathbf{x}) - 2K_{\Phi}(\mathbf{x}, \mathbf{y}) + K_{\Phi}(\mathbf{y}, \mathbf{y}) = (\mathbb{P}(\mathbf{x}) - \mathbb{P}(\mathbf{y}))^2.$$

Este es un ejemplo de kernel generativo.

# Kernel PCA

Ejemplo 4: trabajar con otras normas.

Una elección muy popular es  $K(\mathbf{x}, \mathbf{y}) = \langle \Phi(\mathbf{x}), \Phi(\mathbf{y}) \rangle = e^{-\|\mathbf{x}-\mathbf{y}\|^2/\sigma^2}$ , un kernel de base radial.

$\Phi(\cdot)$  mapea datos a una hiperesfera en  $\mathbb{R}^\infty$ . La función de distancia correspondiente es

$$\|\Phi(\mathbf{x}) - \Phi(\mathbf{y})\|^2 = ke^{-\|\mathbf{x}-\mathbf{y}\|^2/\sigma^2}.$$

