

Esperanza

Sea \vec{x} un vector aleatorio de dimensión p.

$$\vec{x} = \begin{pmatrix} x_1 \\ \dots \\ x_p \end{pmatrix}$$

Esperanza.

$$\vec{\mu} = E(\vec{x}) = \begin{pmatrix} E(x_1) \\ \dots \\ E(x_p) \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \dots \\ \mu_p \end{pmatrix}$$

$$\mu_j = E(x_j), \quad \forall j = 1, \dots, p$$

Matriz de varianzas-covarianzas

$$\Sigma = \text{Cov}(\vec{x}) = E[(\vec{x} - \vec{\mu})(\vec{x} - \vec{\mu})']$$

$$= \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2p} \\ \dots & \dots & \dots & \dots \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_{pp} \end{pmatrix}$$

donde

- Varianza de x_j .

$$\sigma_{jj} = E[(x_j - \mu_j)(x_j - \mu_j)] = \sigma_j^2, \quad j = 1, \dots, p$$

- Covarianza de x_j, x_k .

$$\sigma_{jk} = E[(x_j - \mu_j)(x_k - \mu_k)] \quad \forall j \neq k$$

Si $\sigma_{jk} = 0 \iff x_j$ y x_k son linealmente independientes

La independencia implica la independencia lineal. Lo contrario no suele ser cierto

Transformaciones lineales

Sea A una matriz de elementos fijos con dimensiones (q,p) .

Se define una transformación lineal de \vec{x} como el vector aleatorio $\vec{y} = A\vec{x}$:

$$\vec{y} = A\vec{x} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1q} \\ a_{21} & a_{22} & \dots & a_{2q} \\ \dots & \dots & \dots & \dots \\ a_{q1} & a_{q2} & \dots & a_{qp} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_p \end{pmatrix} = \begin{pmatrix} \vec{a}'_1 \\ \vec{a}'_2 \\ \dots \\ \vec{a}'_q \end{pmatrix} \vec{x}$$

con $\vec{a}'_j = (a_{j1}, \dots, a_{jp})$ fila j de A .

$$y_j = \vec{a}'_j \vec{x} = \sum_{k=1}^p a_{jk} x_k, \quad j = 1, \dots, q$$

Esperanza de una transformación lineal

$$\vec{y} = A\vec{x} \iff y_j = \sum_{k=1}^p a_{jk} x_k, \quad j = 1, \dots, q$$

$$E(y_j) = E\left(\sum_{k=1}^p a_{jk} x_k\right) = \sum_{k=1}^p a_{jk} E(x_k) = \sum_{k=1}^p a_{jk} \mu_k = \vec{a}_j \cdot \vec{\mu}$$

Por tanto

$$E(\vec{y}) = E(A\vec{x}) = AE(\vec{x}) = A\vec{\mu}$$

Covarianza de una transformación lineal

$$\vec{y} = A\vec{x} \iff y_j = \sum_{k=1}^p a_{jk} x_k$$

$$\text{Cov}(\vec{y}) = \begin{pmatrix} \text{Cov}(y_1, y_1) & \text{Cov}(y_1, y_2) & \dots & \text{Cov}(y_1, y_q) \\ \text{Cov}(y_2, y_1) & \text{Cov}(y_2, y_2) & \dots & \text{Cov}(y_2, y_q) \\ \dots & \dots & \dots & \dots \\ \text{Cov}(y_q, y_1) & \text{Cov}(y_q, y_2) & \dots & \text{Cov}(y_q, y_q) \end{pmatrix}$$

$$\text{Cov}(y_i, y_j) = E[(y_i - E(y_i))(y_j - E(y_j))]$$

$$= E[\vec{a}_i'(\vec{x} - \vec{\mu})(\vec{x} - \vec{\mu})' \vec{a}_j] = \vec{a}_i' E[(\vec{x} - \vec{\mu})(\vec{x} - \vec{\mu})'] \vec{a}_j = \vec{a}_i' \Sigma \vec{a}_j$$

$$\Rightarrow \text{Cov}(\vec{y}) = A \Sigma A'$$

Derivadas parciales

Sea $g(\vec{x}) = \vec{a}' \vec{x} = \sum_{k=1}^p a_k x_k$, con $\vec{a}' = (a_1, \dots, a_p)$. Entonces

$$\frac{\partial g}{\partial \vec{x}} = \begin{pmatrix} \frac{\partial g}{\partial x_1} \\ \frac{\partial g}{\partial x_2} \\ \dots \\ \frac{\partial g}{\partial x_p} \end{pmatrix} = \begin{pmatrix} a_1 \\ a_2 \\ \dots \\ a_p \end{pmatrix} = \vec{a}$$

Derivadas parciales

Sea $g(\vec{x}) = \vec{x}' A \vec{x}$ una transformación cuadrática de X , con

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1p} \\ a_{21} & a_{22} & \dots & a_{2p} \\ \dots & \dots & \dots & \dots \\ a_{p1} & a_{p2} & \dots & a_{pp} \end{pmatrix} = \begin{pmatrix} \vec{a}'_1 \\ \vec{a}'_2 \\ \dots \\ \vec{a}'_p \end{pmatrix} = \begin{pmatrix} \vec{a}_{(1)} \\ \vec{a}_{(2)} \\ \dots \\ \vec{a}_{(p)} \end{pmatrix}$$

donde:

$$\vec{a}'_j = (a_{j1}, \dots, a_{jp}) \text{ fila } j \text{ de } A$$

$$\vec{a}_{(k)} = \begin{pmatrix} a_{1k} \\ a_{2k} \\ \dots \\ a_{pk} \end{pmatrix} \text{ columna } k \text{ de } A$$

Derivadas parciales

$$g(\vec{x}) = \sum_{j=1}^p \sum_{k=1}^p a_{jk} x_j x_k = \sum_{j=1}^p a_{jj} x_j^2 + \sum_{j \neq k} a_{jk} x_j x_k$$

$$\frac{\partial g}{\partial x_1} = 2 a_{11} x_1 + \sum_{j \neq 1} a_{j1} x_j + \sum_{k \neq 1} a_{k1} x_k$$

$$= \sum_{j=1}^p a_{j1} x_j + \sum_{k=1}^p a_{k1} x_k = \vec{a}'_1 \vec{x} + \vec{a}'_{(1)} \vec{x} = (\vec{a}'_1 + \vec{a}'_{(1)}) \vec{x}$$

Por tanto,

$$\frac{\partial g}{\partial \vec{x}} = \begin{pmatrix} \vec{a}'_1 + \vec{a}'_{(1)} \\ \vec{a}'_2 + \vec{a}'_{(2)} \\ \dots \\ \vec{a}'_p + \vec{a}'_{(p)} \end{pmatrix} \vec{x} = (A + A') \vec{x}$$

Proyecciones ortogonales

- Si Ω es un subespacio vectorial de \mathbb{R}^n entonces todo vector $y \in \mathbb{R}^n$ se puede descomponer de forma única como $y = u + v$, $u \in \Omega$, $v \in \Omega^\perp$
- Si Ω es un subespacio vectorial de \mathbb{R}^n existe una única matriz que verifique la condición: $P_\Omega y = u$.
 - $P_\Omega = X(X^t X)^{-1} X^t$, donde X es una base del subespacio.
 - Es simétrica e idempotente
$$P_\Omega P_\Omega = X (X' X)^{-1} X' X (X' X)^{-1} X' = X (X' X)^{-1} X'$$
 - Sea $\vec{z} \in \Omega \iff \vec{z} = X \vec{a}$

$$P_\Omega \vec{z} = X (X' X)^{-1} X' X \vec{a} = X \vec{a} = \vec{z}$$

- Sea $\vec{w} \in \Omega^\perp \iff \vec{z}' \vec{w} = 0 \quad \forall \vec{z} \in \Omega$

$$P_\Omega \vec{w} = X (X' X)^{-1} X' \vec{w} = \vec{0}$$

- P proyecta cualquier vector de \mathbb{R}^n ortogonalmente sobre Ω

Matriz de proyección ortogonal

- La matriz $Q_{\Omega} = I - P_{\Omega}$ también es simétrica e idempotente y proyecta ortogonalmente sobre Ω^{\perp} . $\text{rango}(I - P) = n - p$
- La matriz $H = I - \vec{1}(\vec{1}\vec{1}')^{-1}\vec{1}' = I - \frac{1}{n}\vec{1}\vec{1}'$ se denomina matriz de centrado. $\text{rango}(H) = n - 1$

$$\begin{aligned} H\vec{x} &= \left(I - \frac{1}{n}\vec{1}\vec{1}'\right)\vec{x} = \vec{x} - \frac{1}{n}\vec{1}\vec{1}'\vec{x} = \vec{x} - \bar{x}\vec{1} \\ &= \begin{pmatrix} x_1 - \bar{x} \\ x_2 - \bar{x} \\ \dots \\ x_n - \bar{x} \end{pmatrix} \end{aligned}$$

Distribución normal p dimensional

Un vector aleatorio \vec{x} con distribución Normal de media $\vec{\mu}$ y matriz de varianzas covarianzas Σ , $\Sigma > 0$, cumple:

- La función de densidad es:

$$f(\vec{x}) = \frac{1}{\sqrt{2\pi|\Sigma|}} \exp\left(\frac{-1}{2}(\vec{x} - \vec{\mu})'\Sigma^{-1}(\vec{x} - \vec{\mu})\right)$$

- $\vec{y} = A\vec{x}$ sigue una distribución normal $N(A\vec{\mu}, A\Sigma A')$

$$E(\vec{y}) = A E(\vec{x}) = A\vec{\mu}; \quad \text{Cov}(\vec{y}) = A \text{Cov}(\vec{x}) A' = A\Sigma A'$$

- Si Σ es una matriz diagonal ($\sigma_{jk} = 0$ para $j \neq k$), entonces todas las componentes de \vec{x} son independientes entre si.
- La distribución de x_j es $N(\mu_j, \sigma_{jj}), j = 1, \dots, p$

Distribución normal p dimensional

- El cuadrado de una distribución $N(0, 1)$ sigue una distribución chi-cuadrado con un grado de libertad. $N(0, 1)^2 \equiv \chi_1^2$
- Si $\vec{x} \equiv N_p(\vec{\mu}, \Sigma)$ entonces

$$(\vec{x} - \vec{\mu})' \Sigma^{-1} (\vec{x} - \vec{\mu}) \equiv \chi_p^2$$

- Si $\vec{x} \equiv N_p(\vec{\mu}, I)$ entonces

$$(\vec{x} - \vec{\mu})' (\vec{x} - \vec{\mu}) \equiv \chi_p^2$$

- Si $\vec{x} \equiv N_p(\vec{\mu}, I)$ y H simétrica, idempotente con rango q , entonces

$$(\vec{x} - \vec{\mu})' H (\vec{x} - \vec{\mu}) \equiv \chi_q^2$$

t de Student y F de Fisher-Snedecor

- Dadas dos variables $X \equiv N(0, 1)$ e $Y \equiv \chi_p^2$ independientes

$$t = \frac{X}{\sqrt{Y/p}}$$

sigue una distribución t de Student con p grados de libertad, t_p

- Dadas dos variables $X \equiv \chi_q^2$ e $Y \equiv \chi_p^2$ independientes

$$F = \frac{X/q}{Y/p} = \frac{p}{q} \frac{X}{Y}$$

sigue una distribución F con q, p grados de libertad, $F_{p,q}$

Estimación

Sea x una variable aleatoria con algún parámetro θ desconocido.

Objetivo: aproximar θ a partir de una muestra (x_1, \dots, x_n)

Estimador: transforma la muestra en un valor del parámetro

$$T : (X_1, \dots, X_n) \longrightarrow \Theta$$

Se desconoce $P(\text{cara})$ en una moneda. Se lanza cien veces y se obtienen 52 caras.

$$\hat{P}(\text{cara}) = \frac{52}{100} = 0,52$$

Saber la estatura media de los habitantes de una ciudad. Se elige al azar una muestra de 1000 habitantes y se mide su estatura

$$\hat{\mu} = \frac{1}{1000} \sum_{i=1}^{1000} \text{estatura}_i = 1,78$$

Estimación

Métodos de estimación:

- Máxima verosimilitud: busca el valor del parámetro que hace máxima la verosimilitud de la muestra.

$$\text{Max}_{\theta \in \Theta} L(x_1, \dots, x_n; \theta)$$

- Mínimos cuadrados: busca el valor de θ que minimiza el cuadrado de la distancia entre las muestras y valores teóricos

$$\text{Min}_{\theta \in \Theta} \sum_{i=1}^n (x_i - \text{teor}_i(\theta))^2$$

Propiedades deseables de un estimador:

- Ser centrado y tener varianza pequeña

$$E(T) = \theta; \quad \text{Var}(T) \simeq 0$$

- Tener un error cuadrático medio pequeño: $E(T - \theta)^2 \simeq 0$.