

1 Análisis Multivariado I - Práctica 2 - Parte 1

Test de Hotelling para una muestra

Definición: Se define el elipsoide como el conjunto de puntos $\mathbf{x} \in \mathbb{R}^d$ tales que

$$(\mathbf{x} - \mathbf{b})^T \mathbf{A} (\mathbf{x} - \mathbf{b}) = c^2 \quad (1)$$

donde \mathbf{A} es una matriz definida positiva y \mathbf{b} es el centro del elipsoide.

Si $d = 2$ se llama elipse.

1. En este ejercicio graficaremos elipses. Consideremos la definición dada en (1).

(a) Supongamos que $\mathbf{b} = (0, 0)^T$ y $\mathbf{A} = \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix}$. Desarrollar (1) en este caso y graficar en \mathbb{R}^2 el caso $\lambda_1 = 2$, $\lambda_2 = 3$ y $c = 1$ usando dos funciones (función superior y función inferior) o coordenadas polares.

(b) Considerar el caso \mathbf{A} simétrica y definida positiva. Usar la descomposición espectral para transformar el problema $\mathbf{x}^T \mathbf{A} \mathbf{x} = c^2$ en

$$\mathbf{y}^T \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} \mathbf{y} = c^2$$

Usar la transformación para graficar en \mathbb{R}^2 la elipse que tiene $\mathbf{A} = \begin{pmatrix} 2.5 & -0.5 \\ -0.5 & 2.5 \end{pmatrix}$ y $c = 2$.

(c) ¿Cómo se modifica el ítem anterior si ahora tenemos \mathbf{b} genérico? Graficar en \mathbb{R}^2 la elipse anterior pero ahora centrada en $\mathbf{b} = (1, 3)^T$.

2. Supongamos que los datos de la tabla 2.1 son una muestra aleatoria normal multivariada.

(a) Testear la hipótesis de que el peso medio es 63 kg y la altura media es 1.60m.

(b) Hallar un elipsoide de confianza de nivel 95% para el peso y la altura medios de los indios peruanos.

(c) Usando el test de normalidad, ¿le parece razonable este supuesto? ¿A qué se lo atribuiría? ¿Qué haría?

3. Dada una muestra aleatoria $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n \sim N_d(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, sea $T_{\mathbf{x}}^2$ el estadístico de Hotelling para testear $H_0 : \boldsymbol{\mu} = \boldsymbol{\mu}_0$ versus $H_1 : \boldsymbol{\mu} \neq \boldsymbol{\mu}_0$.

Consideremos la siguiente transformación de los datos. Sean

$$\mathbf{y}_i = \mathbf{A} \mathbf{x}_i + \mathbf{b}$$

con $\mathbf{A} \in \mathbb{R}^{d \times d}$ inversible fija y $\mathbf{b} \in \mathbb{R}^{d \times 1}$, sea $T_{\mathbf{y}}^2$ el estadístico de Hotelling para testear $H_0 : \boldsymbol{\mu}_{\mathbf{y}} = \mathbf{A} \boldsymbol{\mu}_0 + \mathbf{b}$, donde $\boldsymbol{\mu}_{\mathbf{y}} = \mathbb{E}(\mathbf{y}_1)$. Probar que $T_{\mathbf{x}}^2 = T_{\mathbf{y}}^2$.

4. Sea $\mathbf{x}_1, \dots, \mathbf{x}_n$ una m.a. con distribución $N_d(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, dada $\mathbf{C} \in \mathbb{R}^{q \times d}$ con $\text{rango}(\mathbf{C}) = q$ y $\mathbf{b} \in \mathbb{R}^{q \times 1}$, encontrar un test de Hotelling para testear $H_0 : \mathbf{C}\boldsymbol{\mu} = \mathbf{b}$.
5. Sea $\mathbf{x}_1, \dots, \mathbf{x}_n$ una m.a. con distribución $N_d(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ y sea $\mathbf{K} \in \mathbb{R}^{d \times q}$ con $q < d$ y $\text{rango}(\mathbf{K}) = q$. Se quiere testear la hipótesis

$$H_0 : \exists \boldsymbol{\beta} \in \mathbb{R}^{q \times 1} \quad \text{tal que} \quad \boldsymbol{\mu} = \mathbf{K}\boldsymbol{\beta}.$$

- (a) Interpretar el significado de esta hipótesis.
- (b) Mostrar que H_0 puede escribirse como $\mathbf{A}\boldsymbol{\mu} = \mathbf{0}$ para cierta matriz \mathbf{A} y por lo tanto, puede testearse usando un test de Hotelling.
6. Sean $\mathbf{x}_1, \dots, \mathbf{x}_n$ i.i.d. $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ con $\boldsymbol{\mu}^T = (\mu_1, \mu_2)$ y sea $y_i = x_{i1} - x_{i2}$ ($1 \leq i \leq n$). Mostrar que el test T^2 de Hotelling para testear $H_0 : \mu_1 = \mu_2$ versus $H_1 : \mu_1 \neq \mu_2$ es equivalente al test usual para muestras apareadas basado en el estadístico $\bar{y}\sqrt{n}/s_y$.
7. Sean $\phi_i = \mu_i - \mu_d$ ($1 \leq i \leq d-1$). Mostrar que el conjunto de todas las combinaciones lineales $\sum_{i=1}^{d-1} h_i \phi_i$ es equivalente al conjunto de contrastes $\sum_{i=1}^d c_i \mu_i$ ($\sum_{i=1}^d c_i = 0$).
8. Consideremos los 14 datos de la tabla 2.2. Suponiendo que son una muestra normal multivariada:
- (a) Realizar un test para estudiar el supuesto de normalidad multivariada de los datos.
- (b) Testear $H_0 : \boldsymbol{\mu} = (45, 42, 45, 42)^T$.
- (c) Testear la hipótesis de que las medias de los pesos son iguales en las cuatro direcciones.
- (d) Testear la hipótesis de que las medias de los pesos en las direcciones norte y sur son iguales y en las direcciones este y oeste también. Comparar con el resultado obtenido en el inciso (a).
- (e) Encontrar intervalos de confianza simultáneos de nivel 95% para $\mu_1 - \mu_3$ y $\mu_2 - \mu_4$. ¿Qué método conviene usar?
- (f) Construir intervalos de confianza simultáneos de nivel 95% para todos los contrastes $\mathbf{c}^T \boldsymbol{\mu}$ donde $\sum_{i=1}^4 c_i = 0$. Probar que existe \mathbf{c} tal que 0 no pertenece al intervalo de confianza para $\mathbf{c}^T \boldsymbol{\mu}$. Intentar hallarlo explícitamente.