

1. Modelo y regresión lineal

La idea es, a partir del vector de observaciones X (que no es v.a.), obtener un modelo lineal $Y = X\beta + \varepsilon$ para la variable Y . Para obtener esta función lineal se deben estimar los coeficientes β según algún criterio. En dimensión uno, usando error cuadrático, se resuelve

$$\min_{\alpha, \beta \in \mathbb{R}} \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2,$$

de donde

$$\hat{\beta} = \frac{\sigma_{XY}}{\sigma_X^2} \quad \text{y} \quad \hat{\alpha} = \bar{y} - \hat{\beta} \bar{x},$$

con

$$\sigma_X^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \quad \sigma_{XY} = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}.$$

Def 35. (Residuos) $\hat{\varepsilon}_i := y_i - \hat{y}_i$, donde $\hat{y}_i = \hat{\alpha} + \hat{\beta} x_i$.

Def 36. (Coeficiente de correlación lineal o de bondad de ajuste)

$$R^2 := \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n \hat{\varepsilon}_i^2}{\sum_{i=1}^n (y_i - \bar{y})^2}.$$

Notemos que $0 \leq r^2 \leq 1$. El coeficiente de correlación también puede ser escrito como

$$R^2 = \frac{\sigma_{XY}}{\sigma_X^2 \sigma_Y^2} = \hat{\beta}^2 \frac{\sigma_X^2}{\sigma_Y^2}.$$

Supuestos probabilísticos

- Errores centrados: $\mathbb{E}(\varepsilon) = 0$.
- Independencia: $\forall i, j \in [n], \varepsilon_i \perp \varepsilon_j$.
- Homocedasticidad: $\forall i \in [n], \text{Var}(\varepsilon_i) = \sigma^2 < +\infty$.

Modelo lineal general

Sea $Y = (Y_1, \dots, Y_n)$, X la matriz de $n \times p$ de las observaciones, $\beta = (\beta_1, \dots, \beta_p)$ y $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)$. Luego, el modelo es $Y = X\beta + \varepsilon$ y el problema a resolver se escribe como

$$\min_{\beta \in \mathbb{R}^p} \|Y - X\beta\|^2 \quad \text{o} \quad \min_{\beta \in \mathbb{R}^p} \|\varepsilon\|^2.$$

De forma geométrica, esto equivale a buscar $\hat{\beta}$ tal que la proyección ortogonal de Y sobre $\langle X \rangle = \{X\beta : \beta \in \mathbb{R}^p\}$ sea $X\hat{\beta}$. Si X es de rango p (modelo lineal de rango completo), entonces el estimador de mínimos cuadrados $\hat{\beta} = (X'X)^{-1}X'Y$ es la única solución del problema. En este caso $\hat{\beta}$ es insesgado para β .

Con lo anterior $\hat{Y} = X(X'X)^{-1}X'Y$. El proyector sobre $\langle X \rangle$ es $P_{\langle X \rangle} = X(X'X)^{-1}X'$ y el proyector sobre el ortogonal es $P_{\langle X \rangle^\perp} = I - X(X'X)^{-1}X'$, por lo que el vector de residuos es $\hat{\varepsilon} = Y - \hat{Y} = P_{\langle X \rangle^\perp}(Y)$.

Bajo los supuestos pobabilísticos se tiene $\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$. Un estimador de σ^2 basado en $\hat{\varepsilon}$ es $\hat{\sigma}^2 = \frac{1}{n-p} \|\hat{\varepsilon}\|^2$ que resulta ser insesgado para σ^2 .

Teo 5. (Gauss-Markov) Sea Y un n -vector aleatorio de la forma $Y = X\beta + \varepsilon$, donde X es una $n \times p$ matriz conocida de rango p , β un p -vector desconocido y ε es el vector de errores con $\mathbb{E}(\varepsilon) = 0$ y $\text{Var}(\varepsilon) = \sigma^2 I$ con σ^2 desconocido. Sea $\hat{\beta}$ el único estimador de mínimos cuadrados de β . Sea $\phi = a\beta$ una función lineal de β , donde a es un vector conocido. Entonces $a\hat{\beta}$ es el mejor estimador lineal insesgado para ϕ , es decir, para todo estimador lineal insesgado $\tilde{\phi}$ de ϕ se tiene $\text{Var}(a\hat{\beta}) \leq \text{Var}(\tilde{\phi})$.

Modelo lineal general con errores correlacionados

Tenemos el modelo $Y = X\beta + \varepsilon$ con X de rango completo (p) y $\mathbb{E}(\varepsilon) = 0$, pero ahora $\mathbb{E}(\varepsilon \varepsilon') = \sigma^2 \Sigma$, donde Σ es una matriz de $n \times n$ definida positiva.

El estimador de mínimos cuadrados ordinarios es

$$\hat{\beta}_{MCO} = (X'X)^{-1}X'Y$$

y escogiendo A no singular tal que $\Sigma = (A'A)^{-1}$, definimos el estimador de mínimos cuadrados generalizado por

$$\hat{\beta}_{MCG} = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}Y,$$

que también es insesgado para β , y tiene menor varianza.

2. Modelo lineal: Teoría Normal

Además de los supuestos probabilísticos usuales y que la matriz sea de rango completo, se supondrá que $\varepsilon \sim \mathcal{N}(0, \sigma^2 I)$. Recordmos el modelo $Y = X\beta + \varepsilon$. Como los ε_i son v.a. $\mathcal{N}(0, \sigma^2)$ independientes, entonces $Y \sim \mathcal{N}(X\beta, \sigma^2 I)$. Por lo que: $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2 (X'X)^{-1})$. Cada $\hat{\beta}_i \sim \mathcal{N}(\beta_i, \sigma^2 c_{ii})$, donde c_{ii} es el elemento i de la diagonal de $(X'X)^{-1}$.

Podemos construir **intervalos de confianza**, definiendo el pivote

$$\frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{c_{ii}}} \sim \mathcal{N}(0, 1).$$

Si σ es conocido se usa el pivote para encontrar $z_{\alpha/2}$ tal que $P_{\beta_i}(-z_{\alpha/2} \leq \hat{\beta}_i \leq z_{\alpha/2}) = 1 - \alpha$. Si σ no es conocido, entonces se ocupa el pivote

$$\frac{\hat{\beta}_i - \beta_i}{\hat{\sigma} \sqrt{c_{ii}}} \sim t(n-p) \quad \text{con} \quad \hat{\sigma}^2 = \frac{1}{n-p} \sum_{i=1}^n \varepsilon_i^2.$$

Podemos aplicar **test de hipótesis** a este modelo, usando el TRV con $\Theta = \mathbb{R}^p \times (0, +\infty)$ y $\theta = (\beta, \sigma)$. Para este modelo se tienen las siguientes hipótesis usuales:

- (1) $H_0 : \beta = 0$ v/s $H_1 : \beta \neq 0$. H_0 equivale a decir que las variables X son irrelevantes linealmente para Y .
- (2) $H_0 : \beta_i = 0$ v/s $H_1 : \beta_i \neq 0$. H_0 indica que la i -ésima variable X es irrelevante linealmente para Y .
- (3) $H_0 : \beta_1 = \beta_2$ v/s $H_1 : \beta_1 \neq \beta_2$. Esto se puede representar mediante tomando $h = [1, -1, 0, \dots, 0]^t$ de forma que $H_0 : h^t \beta = 0$ y $H_1 : h^t \beta \neq 0$.

Ocupando TRV de nivel α , k_α se puede calcular a partir de

$$\sup_{\theta \in \Theta_0} P_\theta \left(\frac{\|\tilde{\varepsilon}\|^2}{\|\hat{\varepsilon}\|^2} \geq k_\alpha \right) = \alpha,$$

donde $\tilde{\varepsilon} = (Y - X\tilde{\beta})'(Y - X\tilde{\beta})$ con $\tilde{\beta}$ el óptimo de $\sup_{\theta \in \Theta_1} f_\theta(y)$ y $\hat{\varepsilon} = (Y - X\hat{\beta})'(Y - X\hat{\beta})$ con $\hat{\beta}$ el óptimo de $\sup_{\theta \in \Theta_0} f_\theta(y)$.

3. Recuerdos

3.1. Matrices

- $U = (U_1, \dots, U_k)$ con U_i v.a., entonces $E(U) = (E(U_1), \dots, E(U_k))$.
- Si $M = (M_{ij})$ matriz con M_{ij} v.a., $E(M) = (E(M_{ij}))$.
- La matriz de covarianzas de U es $\text{Var}(U) = (\text{Cov}(U_i, U_j))_{i,j=1,\dots,k} = E[(U - E(U))(U - E(U))']$, esta matriz siempre es semidefinida positiva.

3.2. Normal Multivariada

- Sea $U = (U_1, \dots, U_n)$ un vector aleatorio con componentes independientes $U_i \sim \mathcal{N}(0, 1)$, entonces

$$f_U(u) = \left(\frac{1}{2\pi}\right)^{n/2} e^{-\frac{1}{2} \sum_{i=1}^n u_i^2}.$$

- Sea $Z = AU + \mu$ con A matriz invertible y $\mu \in \mathbb{R}^n$, entonces $Z \sim \mathcal{N}(\mu, \Sigma)$ con $\Sigma = AA'$, es decir,

$$f_Z(z) = \frac{(2\pi)^{-n/2}}{\sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(z-\mu)'\Sigma^{-1}(z-\mu)}.$$

- Sea $V = BZ + \nu$, B matriz apropiada, que puede tener $p < n$ filas, entonces $V \sim \mathcal{N}(B\mu + \nu, B\Sigma B')$.
- Sea $U \sim \mathcal{N}_n(0, \sigma^2 I)$, entonces $\frac{\|U\|^2}{\sigma^2} \sim \chi^2(n)$.

3.3. Distribuciones

- (1) (Uniforme) La v.a. X se dice $X \sim U([a, b])$ si tiene función de densidad:

$$f_X(t) = \begin{cases} \frac{1}{b-a} & \text{si } t \in [a, b] \\ 0 & \text{si } t \notin [a, b] \end{cases}$$

$$\text{entonces } F_X(t) = \int_{-\infty}^t f_X(s)ds = \begin{cases} 0 & \text{si } t < a \\ 1 & \text{si } t > b \\ \frac{t-a}{b-a} & \text{si } t \in [a, b] \end{cases}$$

Obs. Si $Y \sim U(0, 1)$ y $X = a + (b - a)Y$, entonces $X \sim U(a, b)$.

- (2) (Exponencial) La v.a. X se dice $X \sim \text{exponencial}(\lambda)$ si tiene función de densidad: $f_X(t) = \lambda e^{-\lambda t} 1_{\{t>0\}}$.

$$\text{entonces } F_X(t) = \int_{-\infty}^t \lambda e^{-\lambda s} 1_{\{s>0\}} ds = (1 - e^{-\lambda t}) 1_{\{t>0\}}.$$

- (3) (Gamma) Diremos que la v.a. X tiene distribución Gamma de parámetros $\lambda, k > 0$ si la densidad de X es

$$f_X(x) = \lambda e^{-\lambda x} \frac{(\lambda x)^{k-1}}{\Gamma(k)}.$$

donde $\Gamma(n) = (n-1)!$ para $n \in \mathbb{N}$. Además, tenemos la identidad $\Gamma(p+1) = p\Gamma(p)$, $\forall p > 0$.

Obs. Si $X \sim \mathcal{N}(0, 1)$, entonces $\mu + \sigma X \sim \mathcal{N}(\mu, \sigma^2)$

- (5) (Chi-cuadrado) La v.a. Z se dice $Z \sim \chi^2(n)$ (n grados de libertad) si tiene densidad:

$$f_X(x) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} 1_{(0, +\infty)}(x).$$

Obs. Si X es v.a. $\mathcal{N}(0, 1)$, entonces $X^2 \sim \chi^2(1)$

- (6) (t-student) Sea U una v.a. $\mathcal{N}(0, 1)$ y V un v.a. $\chi^2(n)$ independiente de U , entonces decimos que $T = \frac{U}{\sqrt{\frac{V}{n}}}$ tiene una distribución t-student con n grados de libertad si su densidad es

$$\Phi_n(t) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{\pi n} \Gamma(\frac{n}{2})} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}.$$