

Lecture : Predicción y Esperanza condicional

Lecturer: F. Baltazar-Larios

Scribe:

1. MOTIVACIÓN

Sea Y una variable aleatoria con esperanza finita. Es fácil verificar que la función, llamada error cuadrático medio (ECM),

$$(1) \quad h(c) := \mathbb{E}[(Y - c)^2],$$

alcanza un mínimo en $c = \mathbb{E}[Y]$.

Ejercicio 1.1. *Probar que la función $h(c)$ definida en (1) tiene un mínimo en $c = \mathbb{E}[Y]$.*

Si queremos "predecir" el valor que tomará Y (cuando no se tiene más información), el mejor candidato (en el sentido de ECM) es su valor esperado.

2. PREDICCIÓN

Consideremos a las variables aleatorias X y Y (dependientes) y supongamos que estamos interesados en "predecir" el valor que tomará Y . Si hemos observado que $X = x$ y no se cuenta con información sobre Y , una forma de intentar "predecir" a Y es como una función $f(x)$ de x . La variable aleatoria $f(X)$ (f medible) se puede construir con el propósito y la llamaremos (estimador) de Y .

Para obtener el mejor estimador de Y usaremos como criterio al ECM, es decir, el mejor estimador de Y será la función medible f tal que minimice $\mathbb{E}[(Y - f(X))^2]$.

Proposición 2.1.

$$\mathbb{E}[(Y - f(X))^2] \geq \mathbb{E}[(Y - E[Y|X])^2],$$

para toda función medible f .

Proof. Tenemos que

$$\begin{aligned} \mathbb{E}[(Y - f(X))^2|X] &= \mathbb{E}[(Y - \mathbb{E}[Y|X] + \mathbb{E}[Y|X] - f(X))^2|X] \\ &= \mathbb{E}[(Y - \mathbb{E}[Y|X])^2|X] + \mathbb{E}[(\mathbb{E}[Y|X] - f(X))^2|X] \\ &\quad + 2\mathbb{E}[(Y - \mathbb{E}[Y|X])(\mathbb{E}[Y|X] - f(X))|X]. \end{aligned} \tag{2}$$

Por otro lado tenemos que

$$\begin{aligned} \mathbb{E}[(Y - \mathbb{E}[Y|X])(\mathbb{E}[Y|X] - f(X))|X] &= \mathbb{E}[Y - \mathbb{E}[Y|X]|X](\mathbb{E}[Y|X] - f(X)) \\ &= (\mathbb{E}[Y|X] - \mathbb{E}[Y|X])(\mathbb{E}[Y|X] - f(X)) \\ &= 0. \end{aligned} \tag{3}$$

De las ecuaciones (2) y (3) obtenemos que

$$(4) \quad \mathbb{E}[(Y - f(X))^2|X] \geq \mathbb{E}[(Y - \mathbb{E}[Y|X])^2|X].$$

Tomando esperanza en ambos lados de la ecuación (4) tenemos que

$$(5) \quad \mathbb{E}[(Y - f(X))^2] \geq \mathbb{E}[(Y - \mathbb{E}[Y|X])^2].$$

□

3. MODELO DE REGRESIÓN

Supongamos que la relación entre las variables aleatorias Y y X está dada por la ecuación

$$(6) \quad Y = f(X) + \varepsilon,$$

donde ε es el error de predicción. Si la función relación tiene una forma lineal obtenemos el llamada **modelo lineal simple** dado por

$$(7) \quad Y = \alpha + \beta X + \varepsilon.$$

La pregunta natural es ¿cómo elegir a α y β de tal forma que el ECM que se cometa sea el menor posible en el momento de predecir.

Tenemos que

$$\mathbb{E}[\varepsilon^2] = \mathbb{E}[(Y - (\alpha + \beta X))^2].$$

Ejercicio 3.1. Probar que la función $g(\alpha, \beta) = \mathbb{E}[(Y - (\alpha + \beta X))^2]$ tiene un mínimo en

$$\alpha^* = \mathbb{E}[Y] - \beta^* \mathbb{E}[X]$$

y

$$\beta^* = \frac{\text{Cov}[X, Y]}{\text{Var}[X]}.$$

A $f^*(X) = \alpha^* + \beta^* X$ se le llama el predictor lineal óptimo (PLO).

Nota 3.1. Cuando $\mathbb{E}[Y|X] = a + bX$ el PLO es la esperanza condicional.

4. EJEMPLO


Definición 4.1. El vector aleatorio (X, Y) tiene distribución Normal bivariada si su función de densidad está dada por

$$f_{X,Y}(x,y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp \left\{ -\frac{(\sigma_2^2(x-\mu_1))^2 + \sigma_1^2(y-\mu_2)^2 - 2\sigma_1^2\sigma_2^2\rho(x-\mu_1)(y-\mu_2)}{2\sigma_1^2\sigma_2^2(1-\rho^2)} \right\}, x,y \in \mathbb{R},$$

donde $\mathbb{E}[X] = \mu_1, \mathbb{E}[Y] = \mu_2, \text{Var}[X] = \sigma_1^2, \text{Var}[Y] = \sigma_2^2$ y $\rho = \rho(X, Y)$.

Supongamos que las variables aleatorias X y Y tienen distribución normal. En la Figura 1 se ilustra la relación entre variables de este tipo cuando $X \sim N(0, 1)$ y tenemos observados 100 valores de cada variable aleatoria.

Ejercicio 4.1. Encontrar el PLO cuando $X \sim N(0, 1)$ y $Y \sim N(0, 1)$ tienen distribución normal y hacer predicción sobre Y .

FIGURE 1. Relación entre las variables X e Y .

En la Figura 2 se muestra el PLO con los datos de la Figura 1.




FIGURE 2. Los puntos son los datos y la recta (rojo) es la curva que mejor ajusta y es el PLO.

b

Algorithm 1 Teorema del Límite Central

1: Escribir a la variable aleatoria de interés Z como la suma de v.a.i.i.d.

$$Z = \sum_{i=1}^n X_i,$$

donde $\mathbb{E}[X_i] = \mu$ y $\text{Var}[X_i] = \sigma^2$

2: Encontrar la $\mathbb{E}[Z] = n\mu$ y $\text{Var}[Z] = n\sigma^2$.

3: Concluir que

$$\begin{aligned} \mathbb{P}[z_1 \leq Z \leq z_2] &= \mathbb{P}\left[\frac{z_1 - n\mu}{\sigma\sqrt{n}} \leq \frac{Z - n\mu}{\sigma\sqrt{n}} \leq \frac{z_2 - n\mu}{\sigma\sqrt{n}}\right] \\ &\approx \Phi\left(\frac{z_2 - n\mu}{\sigma\sqrt{n}}\right) - \Phi\left(\frac{z_1 - n\mu}{\sigma\sqrt{n}}\right). \end{aligned}$$

Donde $\Phi(x) = F_X(x)$ para $X \sim N(0, 1)$.
