

# Estadística [continuación]

Santander, 2017-2018

# Regresión lineal con un “feature”: el caso más simple (I)

- Consideremos un problema de regresión lineal donde tan sólo existe una **“feature”**
- El modelo de regresión es por lo tanto de la forma siguiente:

$$y = f(x) = \alpha_0 + \alpha_1 x$$

- Si agrupamos las diferentes medidas de **x** e **y** en la matriz y vectores correspondientes

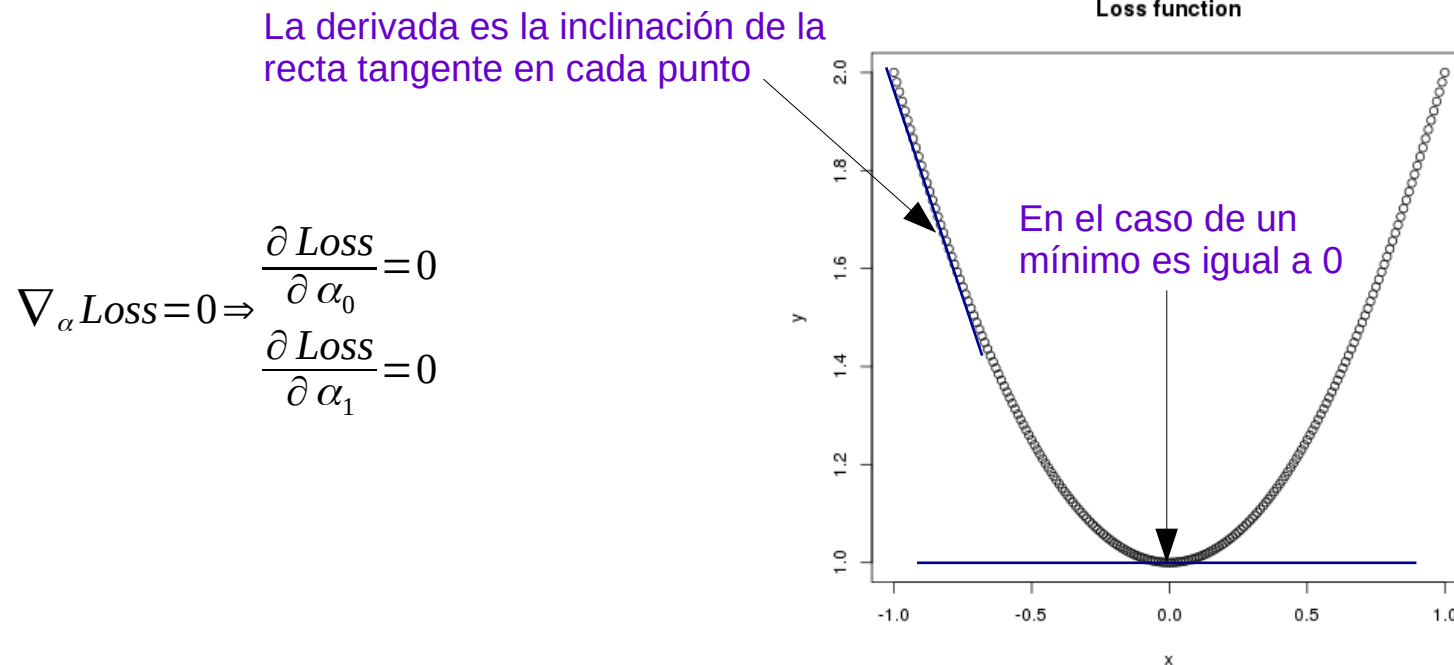
$$\begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(N)} \end{bmatrix} = \begin{bmatrix} 1 & x^{(1)} \\ 1 & x^{(2)} \\ \dots & \dots \\ 1 & x^{(N)} \end{bmatrix} \begin{bmatrix} \alpha_0 \\ \alpha_1 \end{bmatrix}$$

- La forma de la función de coste, utilizando el cuadrado de la distancia euclídea es por lo tanto

$$Loss = (y - X \alpha)^T (y - X \alpha) = \sum_{j=1}^N (y_j - \alpha_0 - \alpha_1 x_j)^2$$

# Regresión lineal con un “feature”: el caso más simple (II)

- Para el caso lineal la minimización de la función de coste puede hacerse analíticamente
- Basta recordar que los mínimos de una función cumplen que la **derivada en ese punto vale 0**



(\*) Los máximos y los puntos de inflexión también cumplen esta condición. En el caso de regresión lineal sabemos que siempre será un mínimo (¿por qué?).

# Regresión lineal con un “feature”: el caso más simple (III)

→ Recuperando la expresión de la función de coste:

$$Loss = (y - X \alpha)^T (y - X \alpha) = \sum_{j=1}^N (y_j - \alpha_0 - \alpha_1 x_j)^2$$

→ Resulta sencillo ver cuáles son las condiciones que han de cumplir los parámetros

$$\begin{aligned} \nabla_{\alpha} Loss = 0 \Rightarrow \frac{\partial Loss}{\partial \alpha_0} &= -2 \sum_{j=0}^N (y_j - \alpha_0 - \alpha_1 x_j) = 0 \\ \frac{\partial Loss}{\partial \alpha_1} &= -2 \sum_{j=0}^N (y_j - \alpha_0 - \alpha_1 x_j) x_j = 0 \end{aligned}$$

→ Es posible despejar  $\alpha_0$  en la primera ecuación para obtener:

$$\alpha_0 = \bar{y} - \alpha_1 \bar{x}$$


→ Sustituyendo en la segunda ecuación:

$$\alpha_1 = \frac{\bar{x}\bar{y} - \bar{x}\bar{y}}{\bar{x}^2 - \bar{x}^2}$$

# Regresión lineal con un “feature”: Ejemplo

→ Generamos un modelo en el que  $y = f(x) = 2x$

→ Y en el que  $p(y | x)$  tiene una forma como la siguiente: 
$$p(y|x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(y-2x)^2}{\sigma^2}}$$



# Regresión lineal en notación matricial: caso general

→ El caso general en el que hay **M features** puede resolverse fácilmente **usando matrices**

$$\begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(N)} \end{bmatrix} = \begin{bmatrix} 1 & x_1^{(1)} & x_2^{(1)} & \dots & x_M^{(1)} \\ 1 & x_1^{(2)} & x_2^{(2)} & \dots & x_M^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_1^{(N)} & x_2^{(N)} & \dots & x_M^{(N)} \end{bmatrix} \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_M \end{bmatrix}$$

→ Como ya hemos visto puede expresarse la función de coste como:

$$Loss = (y - X \alpha)^T (y - X \alpha)$$

→ Que puede ser derivada con respecto a  **$\alpha$**  de la siguiente forma:

$$\nabla_{\alpha} Loss = -X^T (y - X \alpha) = -X^T y + X^T X \alpha = 0$$

→ Multiplicando por la matrix inversa correspondiente podemos despejar el vector  $\alpha$

$$\alpha = (X^T X)^{-1} X^T y$$

# Covarianza de un vector (I)

- El siguiente paso en el que vamos a estar interesados es en calcular **la matriz de covarianza de  $\alpha$**
- Para ello supongamos un vector genérico de dimensión M al que llamaremos **b**

$$b = \begin{bmatrix} b_1 \\ b_2 \\ \dots \\ b_M \end{bmatrix}$$

- La matriz de covarianza es aquella que contiene en la diagonal las **varianzas de  $b_j$**  ...
- ...y las covarianzas correspondientes cruzadas **cov( $b_i, b_j$ )** para los elementos no diagonales

$$\text{Cov}(b) = E[bb^T] - E[b]E[b]^T$$

- En donde se entiende que:

$$bb^T = \begin{bmatrix} b_1 \\ b_2 \\ \dots \\ b_M \end{bmatrix} [b_1 b_2 \dots b_M] = \begin{bmatrix} b_1^2 & b_1 b_2 & \dots & b_1 b_M \\ b_2 b_1 & b_2^2 & \dots & b_2 b_M \\ \dots & \dots & \dots & \dots \\ b_M b_1 & b_M b_2 & \dots & b_M^2 \end{bmatrix}$$

## Covarianza de un vector (II)

→ Volviendo a la definición de covarianza de un vector podemos escribir por lo tanto

$$\text{Cov}(b) = E[bb^T] - E[b]E[b]^T = \begin{bmatrix} E[b_1^2] - E[b_1]^2 & E[b_1 b_2] - E[b_1]E[b_2] & \dots & E[b_1 b_M] - E[b_1]E[b_M] \\ E[b_2 b_1] - E[b_2]E[b_1] & E[b_2^2] - E[b_2]^2 & \dots & E[b_2 b_M] - E[b_2]E[b_M] \\ \dots & \dots & \dots & \dots \\ E[b_M b_1] - E[b_M]E[b_1] & E[b_M b_2] - E[b_M]E[b_2] & \dots & E[b_M^2] - E[b_M]^2 \end{bmatrix}$$

→ Que no es más que la definición de covarianza para un vector:

$$\text{Cov}(b) = \begin{bmatrix} \text{Var}(b_1) & \text{Cov}(b_1, b_2) & \dots & \text{Cov}(b_1, b_M) \\ \text{Cov}(b_2, b_1) & \text{Var}(b_2) & \dots & \text{Cov}(b_2, b_M) \\ \dots & \dots & \dots & \dots \\ \text{Cov}(b_M, b_1) & \text{Cov}(b_M, b_2) & \dots & \text{Var}(b_M) \end{bmatrix}$$

→ Supongamos ahora que el vector  $\mathbf{b}$  es el producto de una matriz constante por un vector  $\mathbf{a}$ ,  $\mathbf{b} = \mathbf{M}\mathbf{a}$

$$\text{Cov}(b) = E[bb^T] - E[b]E[b]^T = \text{Cov}(Ma) = E[Ma(Ma)^T] - E[Ma]E[Ma]^T = E[Maa^T M^T] - E[Ma]E[a^T M^T]$$

$$\text{Cov}(b) = M E[aa^T] M^T - M E[a]E[a^T] M^T = M (E[aa^T] - E[a]E[a^T]) M^T = M \text{Cov}(a) M^T$$



# Cálculo de la covarianza

→ Con estas herramientas en la mano vamos a calcular la matriz de covarianza del vector  $\alpha$ .

$$\alpha = (X^T X)^{-1} X^T y$$

→ La primera pregunta que debemos responder es ¿cuál es el origen de la covarianza de  $\alpha$ ?

→ Hemos asumido que la coordenada independiente  $x$  es fija (su varianza es exactamente 0).

→ Sin embargo la coordenada dependiente está distribuida como  $p(y | x)$  y su varianza no es 0.

→ De hecho hay otras dos asunciones que hemos hecho en el modelo lineal

→ Las medidas de  $y$  son independientes para cada valor de  $x$


→ La varianza de  $y$  es la misma para todas las  $p(y | x)$  con diferentes valores de  $x$ .

→ En estas condiciones se tiene que  $\text{Var}(y_i) = \sigma^2$  y también que  $\text{Cov}(y_i, y_j) = 0$ . Por lo tanto:

$$\text{Cov}(y) = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} \quad \text{Cov}(\alpha) = [(X^T X)^{-1} X^T] \text{Cov}(y) [(X^T X)^{-1} X^T]^T$$


# Ejemplo: efecto de la covarianza en $y$ en $\alpha$

Modelo real:  $y = 2x + N(0, 1)$




Ajuste:  $y = (0.72 \pm 0.42) + (1.95 \pm 0.07) x$

Modelo real:  $y = 2x + N(0, 3)$



Ajuste:  $y = (1.7 \pm 1.3) + (1.75 \pm 0.22) x$


Modelo real:  $y = 2x + N(0, 6)$



Ajuste:  $y = (0.1 \pm 2.5) + (2.15 \pm 0.43) x$

# Regresión lineal para funciones no lineales

- Muchos de los problemas de la vida cotidiana no guardan una relación lineal entre sus variables.
- En ocasiones es posible “traducir” nuestro problema no lineal haciendo un cambio de variable
- Ejemplo: supongamos que medimos el número de núcleos de uranio en una muestra en función de  $t$
- Este tipo de proceso viene dado por una ley exponencial  $N = N_0 \exp(-t/\tau)$
- Obviamente no podemos hacer un ajuste lineal entre  $N$  y “ $t$ ” pero si redefinimos:
  - $Y = \log(N)$  entonces tenemos que:  $y = \log(N_0) - t / \tau$  que es lineal en la variable  $t$



# Regresión lineal para polinomios

- Otra aplicación interesante que podemos considerar a la hora de modelar es usar **polinomios**
- Supongamos el esquema habitual  $\{(y^{(1)}, x^{(1)}), (y^{(2)}, x^{(2)}), \dots, (y^{(N)}, x^{(N)})\}$  con **y** y **x** de dimensión 1
- Podemos **artificialmente** expandir la dimensión de **x** simplemente añadiendo potencias de las **x**

$$\{(y^{(1)}, x^{(1)}), (y^{(2)}, x^{(2)}), \dots, (y^{(N)}, x^{(N)})\} \Rightarrow \{(y^{(1)}, x^{(1)}, x^{(1)2}, \dots, x^{(1)M}), (y^{(2)}, x^{(2)}, x^{(2)2}, \dots, x^{(2)M}), \dots, (y^{(N)}, x^{(N)}, x^{(N)2}, \dots, x^{(N)M})\}$$

- Ahora podemos aplicar la regresión lineal con estas nuevas coordenadas de manera que el modelo:

$$y = f(x) = \alpha_0 + \alpha_1 x_1 + \dots + \alpha_M x_M \Rightarrow y = f(x) = \alpha_0 + \alpha_1 x + \dots + \alpha_M x^M$$


- Con lo cual podemos ajustar un polinomio usando exactamente las mismas herramientas vistas.

$$\begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(N)} \end{bmatrix} = \begin{bmatrix} 1 & x_1^{(1)} & x_2^{(1)} & \dots & x_M^{(1)} \\ 1 & x_1^{(2)} & x_2^{(2)} & \dots & x_M^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_1^{(N)} & x_2^{(N)} & \dots & x_M^{(N)} \end{bmatrix} \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_M \end{bmatrix} \longrightarrow \begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(N)} \end{bmatrix} = \begin{bmatrix} 1 & x^{(1)} & x^{(1)2} & \dots & x^{(1)M} \\ 1 & x^{(2)} & x^{(2)2} & \dots & x^{(2)M} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x^{(N)} & x^{(N)2} & \dots & x^{(N)M} \end{bmatrix} \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_M \end{bmatrix}$$

# Regresión lineal con polinomios: ejemplo

→ Generamos un modelo en el que  $y = f(x) = 2 + (x-1)(x-3)(x-5)(x-7)$


→ Y en el que  $p(y | x)$  tiene una forma como la siguiente: 
$$p(y|x) = \frac{1}{\sqrt{2\pi\sigma}} e^{\frac{-1}{2\sigma^2}(y - (2 + (x-1)(x-3)(x-5)(x-7)))^2}$$



# Regresión lineal con polinomios: ejemplo

→ Generamos un modelo en el que  $y = f(x) = 2 + (x-1)(x-3)(x-5)(x-7)$

→ Y en el que  $p(y | x)$  tiene una forma como la siguiente: 
$$p(y|x) = \frac{1}{\sqrt{2\pi\sigma}} e^{\frac{-1}{2\sigma^2}(y - (2 + (x-1)(x-3)(x-5)(x-7)))^2}$$



# Ejercicio 4

- 1) Crea una función como la del ejercicio 3 en la que se pase como input: un vector  $x$  con la variable independiente, un parámetro “a”, un parámetro “b” y un valor “sigma”; y que devuelva un vector “y” que esté distribuido como una función normal con media =  $a * x + b$  y sigma = “sigma”.
- 2) Construye una función que reciba dos vectores “x” e “y” supuestamente relacionados linealmente y calcule los valores de “a” y “b” que minimizan la función de coste.
- 3) Genera un vector  $x$  aleatorio con valores entre 0 y 8 y  $N = 100$  puntos. Usa la función creada en 1 con valores  $a=1$ ,  $b=2$  y  $\sigma=2$ , y la función creada en 2 para encontrar el mínimo de la función de coste. Pinta en un mismo plot “x” e “y” representados con puntos, y la recta “ $a * x + b$ ”.
- 4) Construye una función que calcule la matriz de covarianza asociada al ajuste lineal anterior. Utilízala con los vectores “x” e “y” anteriores y calcula dicha matriz para ese caso particular.
- 5) Crea una función como la del apartado 1 donde se añadan 3 parámetros más (c, d, e) y en dónde todo sea igual salvo que media =  $a + b * x + c * x^2 + d * x^3 + e * x^4$
- 6) Repite 3 y 4 con la función generada en 5 y usando:  **$a = 107$ ,  $b=-176$ ,  $c=86$ ,  $d=-16$ ,  $e=1$**