

# Linear Regression and the Least-squares problem

Aniel Nieves-González

Abril 2013

# Variables cuantitativas y relaciones entre estas (Repaso)

Recuerde que informalmente...

- Una variable aleatoria (v.a.) es una asociación (relación) entre los miembros del espacio muestral (conjunto de objetos que nos interesa estudiar) y algún conjunto de números.

## Definition (Response variable)

Una v.a. que mide el resultado de un estudio es un response variable. También es llamada **variable dependiente**.



## Definition (Explanatory variable)

Variable que explica o influencia los cambios en el response variable. También es llamada **variable independiente**.



# Sección 2.1, 2.2 (Repaso)

- Dos v.a. están **asociadas positivamente** si valores sobre el prom. de una acompañan a valores sobre el promedio de otra, y valores por debajo del prom. tienden a ocurrir juntos.

- D  
pi  
vi<sup>></sup>



res sobre el  
io de otra, y



## Sección 2.1, 2.2 (Repaso)

El concepto de **correlación** mide cuantitativamente la dirección y fuerza de una relación *lineal* entre dos variables.

### Definition (Correlación de la muestra)

Suponga q. tiene  $n$  datos de las variables  $X$  y  $Y$ . Denotamos dichos datos como  $\{x_1, \dots, x_n\}$  y  $\{y_1, \dots, y_n\}$  respectivamente. Sea  $\bar{X}$  y  $s_x$  la media aritmética y la desviación estándar para los datos de  $X$ .

Análogamente  $\bar{Y}$  y  $s_y$  para con  $Y$ . La **correlación** de la muestra, denotada como  $r$ , entre  $X$  y  $Y$  es

$$r = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{X}}{s_x} \right) \left( \frac{y_i - \bar{Y}}{s_y} \right)$$

## Sección 2.1, 2.2 (Repaso)

Observe:

- $r$  no hace distinción entre var. dependiente e independiente.
- $r$  solo aplica a variables cuantitativas.
- $r$  no tiene unidades (“dimensionless”).
- $r > 0 \Rightarrow$  relación lineal positiva
- $r < 0 \Rightarrow$  relación lineal negativa
- $|r| < 1$  (i.e.  $-1 \leq r \leq 1$ ).
- $r \approx 0 \Rightarrow$  relación lineal débil.
- $r \approx -1$  o  $r \approx 1$  implica relación lineal fuerte.
- Por último:  $r$  mide fuerza de relaciones **lineales** solamente. Y al igual que  $\bar{X}$  no es resistente a outliers.

## Ejemplo 1: Calculando $r$

Suponga los siguientes datos y calcule  $r$ .

rapidez (speed)	20	30	40	50	60
MPG	24	28	30	28	24

Sea  $X \equiv$  'rapidez en mph',  $Y \equiv$  'MPG', y  $n = 5$ .

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{20 + 30 + 40 + 50 + 60}{5} = \frac{200}{5} = 40$$

$$\begin{aligned} s_x^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2 = \frac{(-20)^2 + (-10)^2 + (0)^2 + (-10)^2 + (10)^2}{4} \\ &= \frac{400 + 100 + 0 + 100 + 400}{4} = \frac{1000}{4} = 250 \\ &\Rightarrow s_x = 15.81 \end{aligned}$$

Análogamente:

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{134}{5} = 26.8$$

Recuerde que el modelo ANOVA es:

$$x_{ij} = \mu_i + \epsilon_{ij}$$

Ahora estudiaremos otro modelo usado para estudiar nuestro sistema de interés. Dos v.a. pueden estar relacionadas linealmente o no linealmente. El primero es el tipo de relación entre v.a. más simple.

## Definition (Simple Linear Regression model)


Consider  $n$  observations independent of the independent variable  $X$  and of the dependent variable  $Y$ , where  $Y \sim N(\mu_y, \sigma)$ :

$$\{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i), \dots, (x_n, y_n)\}$$

The **simple linear regression statistical model** is

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

where the parameters of the model are the intercept in  $y$  ( $\beta_0$ ), the slope ( $\beta_1$ ) of the regression line of the population, and the variability in  $y$  around this line ( $\sigma$ ).  $\epsilon_i$  is the random error for the  $i$ -th observation. The  $\epsilon_i$  are independent and are distributed  $N(0, \sigma)$ . Note that  $\mu_y = \beta_0 + \beta_1 X$  is the mean response (mean response) when  $x = x_i$ .



- La meta es obtener de la muestra estimados de  $\beta_0$ ,  $\beta_1$ ,  $\sigma$ . A dichos estimados le llamaremos  $b_0$ ,  $b_1$ , y  $s_{YX}$  respectivamente.
- El término de “regresión” lo acuñó Francis Galton en el s. 19 para describir un fenómeno biológico. El fenómeno consistía en que en promedio la altura de los descendientes tiende a regresar (“regress”) hacia el promedio (regression toward the mean). O sea que la altura de los descendientes de padres altos es menor que la altura de los padres.

## Least-squares regression (regresión por cuadrados mínimos)

En esencia el problema de cuadrados mínimos (o least squares (LS) problem o LS regression) es un problema de minimización, el cual se puede escribir como:

$$\min_{\mathbf{p}} \sum_{i=1}^n (F(x_i, \mathbf{p}) - y_i)^2$$

donde:

- $\{(x_1, y_1), \dots, (x_n, y_n)\}$  son los datos (note las dos variables  $X$  y  $Y$ )
- $\mathbf{p}$  son los parámetros (constantes del modelo matemático).
- $F(x_i, \mathbf{p})$  es el modelo matemático. Note que  $F$  depende de los datos y de los parámetros.
- En este caso el modelo matemático representará a la relación entre las dos variables  $X$  y  $Y$ .
- En LSP se buscan los parámetros del modelo que minimizan la distancia vertical (a lo largo de eje de  $y$ ) entre modelo y datos.

## Least-squares regression

En este caso  $F$  (el modelo) será simple linear regression model, esto es,

$$F(x_i, b_0, b_1) = b_0 + b_1 x_i \quad \text{una función lineal.}$$

$F(x_i, b_0, b_1)$  puede renombrarse como  $\hat{y}_i$ .

Usando técnicas de cálculo multivariable (optimización) se obtienen las *ecuaciones normales*. Las mismas se resuelven para los parámetros ( $b_0$  y  $b_1$  en este caso). Observe que:

- Para la regresión por LS es importante distinguir entre var. independiente y dependiente.
- La pendiente (slope) del LS regression es

$$\begin{aligned} b_1 &= r \frac{s_y}{s_x} = \left( \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{X}}{s_x} \right) \left( \frac{y_i - \bar{Y}}{s_y} \right) \right) \frac{s_y}{s_x} \\ &= \frac{\sum_{i=1}^n x_i y_i - n \bar{X} \bar{Y}}{\sum_{i=1}^n x_i^2 - n \bar{X}^2} \end{aligned}$$

y el intercepto en  $y$  ( $y$ -intercept) es

$$b_0 = \bar{Y} - b_1 \bar{X}$$

Una medida de la variabilidad de alrededor de la línea de regresión es el standard error de la regresión. Este es un estimador de  $\sigma$ . El mismo se define como

$$s_{XY} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - 2}}$$

donde  $\hat{y}_i = b_0 + b_1 x_i$ . Este es un “unbias estimator” de  $\sigma$ .

# Suposiciones para regresión e inferencia

Vimos el planteamiento de simple linear regression model para estudiar la relación entre dos v.a. y como se encuentran los parámetros de la línea resolviendo el LSP. Ahora estudiaremos las condiciones que se deben cumplir si queremos hacer inferencia con la regresión lineal.

# Suposiciones para regresión e inferencia

Las cuatro suposiciones importantes en la regresión lineal son:

- 1 *Normality*: se requiere que los valores de  $Y$  estén normalmente distribuidos para cada valor de  $X$ . (El análisis de regresión es robusto para violaciones de esta suposición).
- 2 *Homoscedasticity (Homocedastisidad)*: se requiere la variación alrededor de la línea de regresión sea constante para todos los valores de  $X$  ( $\sigma$  constante).
- 3 *Independence of error* (la muestra es un SRS): se requiere que el error residual ( $y_i - \hat{y}_i$ ) sea independiente para cada valor de  $x_i$ .
- 4 *Linealidad*: se requiere que la relación entre las variables sea lineal. (Dos variables pueden estar relacionadas en forma no lineal y el coef. de correlación lineal puede ser cero.)

# Intervalos de confianza (IC) y test de significancia (TS)

Los IC para la pendiente e intercepto en  $y$  son de la forma:

$$\text{estimate} \pm t^* \text{SE}_{\text{estimate}}$$

donde  $t^*$  es el valor crítico de la dist.  $t$ .

IC para  $\beta_1$  y  $\beta_0$  están basados en las dist. de  $b_1$  y  $b_0$ :

- Cuando el modelo de regresión lineal es cierto  $b_0, b_1$  se dist. normalmente.
- $\mu_{b_0} = \beta_0$  y  $\mu_{b_1} = \beta_1$ . Esto es,  $b_0$  y  $b_1$  son estimadores sin sesgo de  $\beta_0$  y  $\beta_1$ .
- $\sigma_{b_0}$  y  $\sigma_{b_1}$  son multiples de  $\sigma$ .

# Intervalos de confianza (IC) y test de significancia (TS)

## Definition (Inferencia para la pendiente)

Un IC de nivel  $C$  para pendiente  $\beta_1$  de la línea de regresión de la población es:

$$b_1 \pm t^* SE_{b_1}$$

Donde el área bajo la curva de densidad de  $t(n-2)$  y sobre el intervalo  $[-t^*, t^*]$  es igual a  $C$ . El Margen de error (MOE) es  $t^* SE_{b_1}$  y el standard error de  $b_1$  ( $SE_{b_1}$ ) es:

$$SE_{b_1} = \frac{s_{YX}}{\sqrt{\sum_{i=1}^n x_i^2 - n\bar{X}^2}}$$

# Intervalos de confianza (IC) y test de significancia (TS)

## Definition (Inferencia para la pendiente)

Para el test de hipótesis  $H_0 : \beta_1 = 0$  (no relación lineal entre  $X$  y  $Y$ ) se calcula la estadística  $t$

$$t = \frac{b_1}{\text{SE}_{b_1}}$$

En términos de una v.a.  $T$  que se distribuye con  $t(n - 2)$ , el P-value para probar  $H_0$  en contra de  $H_a$  es:

$$H_a : \beta_1 > 0 \quad \text{es} \quad P(T \geq t)$$

$$H_a : \beta_1 < 0 \quad \text{es} \quad P(T \leq t)$$

$$H_a : \beta_1 \neq 0 \quad \text{es} \quad P(T \geq t) + P(T \leq -t) = 2P(T > |t|)$$

## Intervalos de confianza (IC) y test de significancia (TS)

- Los IC y TS para el intercepto en  $y$  son análogos a los de la pendiente (cambie subscrito en las expresiones, de 1 a 0) y use la siguiente expresión para el SE:

$$SE_{b_0} = s_{XY} \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum_{i=1}^n x_i^2 - n\bar{X}^2}}$$

- *Regression fallacy*: Es suponer que “regression toward the mean” es consecuencia de algún efecto sistemático. O sea es la falla de no considerar fluctuaciones naturales del sistema bajo consideración.

# Inferencia y correlación

El concepto de correlación de la muestra puede generalizarse a la correlación de la población ( $\rho$ ).

- Este será un parámetro de la población y el estimador correspondiente es  $r$  (correlación de la muestra).
- Este es un número con las propiedades y la interpretación de  $r$ .
- La pendiente de la línea de regresión de la población ( $\beta_1$ ) nos da info. de  $\rho$ .
- De hecho, cuando  $\beta_1$  es cero, positiva, o negativa entonces también lo es  $\rho$ .

## Inferencia y correlación (no se embotelle este slide...)

Si  $X$  y  $Y$  son dos v.a. la correlación  $\rho$  se define como

$$\begin{aligned}\rho &= \text{Cov}\left(\frac{X - E[X]}{\sigma_X}, \frac{Y - E[Y]}{\sigma_Y}\right) \\ &= \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}\end{aligned}$$

donde  $E[X]$  y  $E[Y]$  denotan  $\mu_X$  y  $\mu_Y$  respectivamente,  $\text{Cov}(X, Y)$  es la covarianza de  $X$  y  $Y$  (i.e.  $\text{Cov}(X, Y) = E[(X - E[X])(Y - E[Y])]$ ), y  $\sigma_X$ ,  $\sigma_Y$  son la desv. estándar de  $X$  y  $Y$  respectivamente. Note,  $\text{Cov}(X, X)$  es igual a...

## Inferencia y correlación

Conociendo  $r$ : ¿que podemos inferir sobre  $\rho$ ?

### Definition (Test for zero population correlation)

Considere el test de hipótesis

$$H_0 : \rho = 0 \quad \text{no correlación}$$

$$H_a : \rho \neq 0 \quad \text{hay correlación}$$

Puede definirse una estadística  $t$  usando a  $r$ :

$$t = \frac{r - \rho}{\sqrt{\frac{1-r^2}{n-2}}}$$

y usar la dist.  $t$  con  $n - 2$  grados de libertad para calcular P-value.

Note que para probar  $H_0$  se toma  $\rho = 0$  en la def. anterior de la estadística  $t$ .

## Usando la línea de regresión

La idea de la regresión lineal es estudiar la relación (si alguna) entre dos v.a. y hacer predicciones (cuidado con extrapolación). Considere el siguiente ejemplo:

## Ejemplo:

Considere el “stock market”. Algunos piensan que el comportamiento del stock market a principios del año predice lo que ocurriría el resto del año. Ahora, suponga que  $X$  es la variable independiente y  $Y$  la dependiente donde:

$X \equiv$  tasa de cambio en el stock market index en enero

$Y \equiv$  tasa de cambio en el stock market index en el resto del año

Los datos en los últimos 38 años se resumen como sigue:  $\bar{X} = 0.0175$ ,  $\bar{Y} = 0.0907$ ,  $s_x = 0.0536$ ,  $s_y = 0.1535$ , y  $r = 0.596$

- 1 Calcule la línea de regresión:

$$b_1 = r \frac{s_y}{s_x} = (0.596) \frac{0.1535}{0.0536} = 1.7068$$

$$b_0 = \bar{Y} - b_1 \bar{X} = 0.0907 - (1.7068)(0.0175) = 0.0608$$

$$\Rightarrow \hat{y}_i = 1.7068x_i + 0.0608$$

- 2 Suponga que sus datos para  $X$  fluctúan entre 0.005 y 0.03. Si queremos predecir el valor de  $\hat{Y}$  para  $x = 0.012$ , que hacemos...

$$\hat{Y}(0.012) = 1.7068(0.012) + 0.0608 = 0.0813$$

## Usando la línea de regresión

Ahora, si en lugar de querer predecir el valor de  $Y$  para un posible valor en particular de  $X$  (ejemplo anterior), queremos estimar el “mean response” de  $Y$  (i.e.  $\mu_y$ ) entonces necesitamos construir un IC para  $\beta_0$  y  $\beta_1$ .