

Estadística I

Tema 3: Análisis de datos bivariantes

Tema 3: Análisis de datos bivariantes

Contenidos

3.1 Tablas de doble entrada.

- ▶ Datos bivariantes.
- ▶ Estructura de la tabla de doble entrada.
- ▶ Distribuciones de frecuencias marginales.
- ▶ Distribución conjunta de frecuencias relativas.
- ▶ Distribuciones de frecuencias condicionadas.
- ▶ Tabla de doble entrada para variables cuantitativas.

3.2 Correlación.

- ▶ Diagrama de dispersión.
- ▶ Tipos de relación entre dos variables cuantitativas.
- ▶ Medidas de dependencia lineal.
- ▶ Correlación y heterogeneidad.
- ▶ Correlación y datos atípicos.
- ▶ Correlación y causalidad.

Tema 3: Análisis de datos bivariantes

3.3 Recta de regresión.

- ▶ Definición de la recta.
- ▶ Estimación de los coeficientes.
- ▶ Interpretación de los coeficientes.
- ▶ Valores predichos, residuos y varianza residual.
- ▶ Bondad del ajuste.
- ▶ Análisis de residuos.
- ▶ Los datos de *Anscombe*.

Tema 3: Análisis de datos bivariantes

Lecturas recomendadas

- ▶ Peña, D. y Romo, J., *Introducción a la Estadística para las Ciencias Sociales*.
 - ▶ Capítulos 7, 8 y 9.
- ▶ Newbold, P. *Estadística para los Negocios y la Economía*.
 - ▶ Secciones 2.5 y 12.1–12.4.

Datos bivariantes

Ejemplo Nivel educativo (X) y situación laboral (Y) de 10 Madrileños.

Nivel educativo (1=Primaria o menos, 2=Secundaria, 3=Post-secundaria)

Situación laboral (1=Empleado, 2=Desempleado, 3=Inactivo)

Individuo	1	2	3	4	5	6	7	8	9	10
Nivel educativo (X)	2	3	2	3	2	2	1	1	3	2
Situación laboral (Y)	3	1	1	3	3	3	3	3	1	3

Datos bivariantes

- ▶ **Datos bivariantes:** provienen de la observación simultánea de dos variables (X, Y) en una muestra de n individuos. Los datos bivariantes son parejas de valores, numéricos o no, de la forma:

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$$

- ▶ Se usan para describir las dos variables conjuntamente o una variable en función de la otra.
- ▶ A menudo se intenta describir el comportamiento de una de las variables, que se llama la variable **dependiente** y se denota por Y , en función de la otra variable, que se llama la variable **independiente** o **explicativa**, y se denota por X .

Estructura de la tabla de doble entrada

- ▶ Representamos los valores de una de las variables (p.ej. X) en las cabeceras de las filas de una tabla, y los valores de la otra variable (p.ej. Y) en las cabeceras de las columnas de la tabla.
- ▶ En la casilla correspondiente a cada par de valores de X e Y , se escribe la frecuencia absoluta o número de individuos en cada combinación de valores.
- ▶ Cuando al menos alguna de las dos variables es cualitativa, la tabla de doble entrada también se denomina **tabla de contingencia**.

Estructura de la tabla de doble entrada/tabla de contingencia

Ejemplo Datos de 1508 madrileños (Encuesta de Condiciones de Vida). X : Nivel educativo, Y : Situación laboral

		Y		
		Empleado	Desempleado	Inactivo
X	Primaria	95	6	315
	Secundaria	393	28	257
	Post-secundaria	317	8	89

- ▶ Se denomina distribución conjunta de (X, Y) al conjunto formado por los valores observados en forma de pares, junto con las frecuencias absolutas correspondientes a cada par.

Estructura de la tabla de doble entrada

- ▶ Tabla de doble entrada con k filas y m columnas

		Y					Total
		y_1	\cdots	y_j	\cdots	y_m	
X	x_1	n_{11}	\cdots	n_{1j}	\cdots	n_{1m}	$n_{1\cdot}$
	\vdots	\vdots		\vdots		\vdots	\vdots
	x_i	n_{i1}	\cdots	n_{ij}	\cdots	n_{im}	$n_{i\cdot}$
	\vdots	\vdots		\vdots		\vdots	\vdots
	x_k	n_{k1}	\cdots	n_{kj}	\cdots	n_{km}	$n_{k\cdot}$
Total		$n_{\cdot 1}$	\cdots	$n_{\cdot j}$	\cdots	$n_{\cdot m}$	$n_{\cdot\cdot}$

- ▶ Notación:

n_{ij} frecuencia **absoluta** en la casilla (i, j)

Total de fila i : $n_{i\cdot} = n_{i1} + n_{i2} + \cdots + n_{im}$

Total de columna j : $n_{\cdot j} = n_{1j} + n_{2j} + \cdots + n_{kj}$

$n_{\cdot\cdot}$ tamaño muestral $n_{\cdot\cdot} = n$

Distribuciones de frecuencias marginales

- ▶ Los totales de las filas (columnas) se llaman frecuencias absolutas **marginales** de las filas (columnas).
- ▶ Éstas son las frecuencias univariantes de X y de Y .

Ejemplo Distribuciones de frecuencias marginales:

Nivel educativo (X)	Primaria	Secundaria	Post-secundaria	Total
$n_{i\cdot}$	416	678	414	1508
Situación laboral (Y)	Empleado	Desempleado	Inactivo	Total
$n_{\cdot j}$	805	42	661	1508

Distribuciones de frecuencias marginales

- ▶ Se denomina distribución marginal de X al conjunto de valores que toma X junto con sus frecuencias absolutas marginales.
- ▶ Análogamente se define la distribución marginal de Y .
- ▶ **Observación:** Si en lugar de tener dos variables (X, Y) tuviéramos tres (X, Y, Z) tendríamos tres distribuciones marginales.

Distribución conjunta de frecuencias relativas

- ▶ $f_{ij} = n_{ij}/n..$ frecuencia **relativa** en la casilla (i, j)

		Y					Total
		y_1	\cdots	y_j	\cdots	y_m	
X	x_1	f_{11}	\cdots	f_{1j}	\cdots	f_{1m}	$f_{1.}$
	\vdots	\vdots		\vdots		\vdots	\vdots
	x_i	f_{i1}	\cdots	f_{ij}	\cdots	f_{im}	$f_{i.}$
	\vdots	\vdots		\vdots		\vdots	\vdots
	x_k	f_{k1}	\cdots	f_{kj}	\cdots	f_{km}	$f_{k.}$
Total	$f_{.1}$	\cdots	$f_{.j}$	\cdots	$f_{.m}$	1	

- ▶ Frecuencia relativa **marginal** de la fila i :

$$f_{i.} = f_{i1} + \cdots + f_{ij} + \cdots + f_{im}$$

- ▶ Frecuencia relativa **marginal** de la columna j :

$$f_{.j} = f_{1j} + \cdots + f_{ij} + \cdots + f_{kj}$$

Distribución de frecuencias condicionadas

- ▶ Dada la distribución conjunta de (X, Y) , se denomina distribución condicionada a la distribución de frecuencias absolutas de una de las variables, suponiendo conocido y fijado el valor de la otra variable.

Ejemplo Distribución de frecuencias de la situación laboral (Y) para personas con un nivel educativo (X) de Primaria o menos.

$Y X = \text{Primaria}$	Empleado	Desempleado	Inactivo	Total
n_{1j}	95	6	315	416

- ▶ Distribución de frecuencias de Y condicionado a $X = x_j$: Es la distribución de frecuencias de la variable Y , de entre los individuos que han tomado el valor x_j de X .
- ▶ observa que se restringe al conjunto total de individuos que toman el valor x_j de X .
- ▶ **Notación:** $Y|X = x_j$.

Distribución de frecuencias condicionadas

Ejemplo Distribución de frecuencias del nivel educativo para inactivos.

$X Y = \text{Inactivo}$	Primaria	Secundaria	Post-secundaria	Total
n_{i3}	315	257	89	661

Distribución de frecuencias del nivel educativo para desempleados.

$X Y = \text{Desemp.}$	Primaria	Secundaria	Post-secundaria	Total
n_{i2}	6	28	8	42

Se ha visto, así, la definición más sencilla de distribución condicionada. Puede condicionarse también al hecho de que la variable tome varios valores, por ejemplo:

$X|(Y = \text{Inactivo}) \cup (Y = \text{Desempleado})$.

Tabla de doble entrada para variables cuantitativas

Ejemplo 43 alumnos encuestados

X: Núm. de veces que han ido al teatro en el último mes

Y: Núm. de veces que han ido al cine en el último mes

		Y					Total
		0	1	2	3	4	
X	0	12	5	4	2	1	24
	1	4	3	2	1	0	10
	2	3	3	2	0	0	8
	3	1	0	0	0	0	1
Total		20	11	8	3	1	43

- ▶ Si X e Y son **cuantitativas discretas** tomando un número pequeño de valores, la tabla se construye de la misma forma que para el caso de variables cualitativas.

Tabla de doble entrada para variables cuantitativas

Ejemplo Empresas americanas

X: Núm. de trabajadores, Y: Volumen de ventas


		X				Total
		[1,25)	[25,50)	[50,75)	[75,99]	
Y	[1,100)	0.293	0.122	0.098	0.049	0.561
	[100,200)	0.098	0.073	0.049	0.024	0.244
	[200,300]	0.073	0.073	0.049	0.000	0.195
Total		0.463	0.268	0.195	0.073	1.000

- ▶ Si X e Y son, bien **cuantitativas discretas** tomando un número grande de valores o bien **continuas**, es habitual agrupar los valores de las variables en intervalos.


Diagrama de dispersión

- ▶ La representación gráfica más común para dos variables **cuantitativas** es el **diagrama de dispersión**

Ejemplo m^2 habitables y Precio de 15 viviendas.




Tipos de relación entre variables cuantitativas



Medidas de dependencia lineal para variables cuantitativas

- ▶ La covarianza es una medida de variación conjunta de las dos variables. **Cuantifica la información existente en un gráfico de dispersión sobre la asociación lineal** entre dos variables.



Covarianza:

$$s_{xy} = \frac{1}{n-1} \left(\underbrace{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}_{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})} \right) \quad -\infty < s_{xy} < \infty$$

Medidas de dependencia lineal

- ▶ $s_{xy} \gg 0 \Rightarrow$ Relación **lineal positiva**.
- ▶ $s_{xy} \ll 0 \Rightarrow$ Relación **lineal negativa**.
- ▶ $s_{xy} \approx 0 \Rightarrow$ **No existe relación lineal** o existe relación **no lineal**.
- ▶ Inconvenientes de la covarianza:
 - ▶ No está acotada ni superior ni inferiormente. Por lo tanto no se sabe cuándo es s_{xy} suficientemente grande o pequeña.
 - ▶ Depende de las unidades de medida de las variables:
Si s_{xy} es la covarianza de X e Y , y $a, b \in \mathbb{R}$, $b \neq 0$ y $T = a + bY$, entonces:
 $s_{xt} = bs_{xy}$

Medidas de dependencia lineal


- ▶ **Coefficiente de correlación lineal de Pearson:**

$$r_{(x,y)} = \frac{S_{xy}}{S_x S_y}$$


- ▶ ¿Ventajas?

- ▶ Está **acotado**: $-1 \leq r_{(x,y)} \leq 1$
- ▶ Es **adimensional**.
- ▶ Interpretación del coeficiente de correlación de Pearson:
 - ▶ $r_{(x,y)} > 0$ Dependencia Directa.
 - ▶ $r_{(x,y)} < 0$ Dependencia Indirecta.
 - ▶ $|r_{(x,y)}| = 1$ Relación Lineal Perfecta.
 - ▶ $r_{(x,y)} = 0$ X e Y están Incorreladas (ausencia de relación **lineal**).

Correlación y heterogeneidad




Correlación y datos atípicos




Correlación \neq Causalidad

Correlación no es causalidad!!



Recta de regresión

Ejemplo Diagrama de dispersión de Y : Ingresos netos frente a X : Años de estudio para 1508 madrileños.



- ▶ Los ingresos netos medios para cada valor de años de estudio (medias de Y condicionadas a cada valor de X) forman aproximadamente una línea recta.



Definición de la recta de regresión

- ▶ Dada una muestra de n puntos (x_i, y_i) queremos encontrar la recta $y = a + bx$ que mejor se ajuste a la nube de puntos.
- ▶ Ecuación de la recta de regresión:

$$\hat{y} = a + bx$$

Recta de regresión

Cuando existe una relación lineal, la forma natural de expresar esta relación es a través de la **recta** que describe la evolución conjunta de ambas variables



residuo
 $(y_i - \hat{y}_i)$

Generalizando el concepto de la media de una variable.....
... se llega a la **recta de medias**
→ **método de mínimos cuadrados** minimizando los residuos cuadráticos

Estimación de los coeficientes

- ▶ Calculamos la ordenada en origen a y la pendiente b minimizando los residuos al cuadrado (método de **mínimos cuadrados**):

$$\min_{a,b} \sum_{i=1}^n \overbrace{(y_i - \hat{y}_i)^2}^{\text{residuo}} = \min_{a,b} \sum_{i=1}^n (y_i - (a + bx_i))^2$$

- ▶ Estimadores de b y a :

$$b = \frac{s_{xy}}{s_x^2}$$
$$a = \bar{y} - b\bar{x}$$

- ▶ Propiedad: $b = r_{(x,y)} \frac{s_y}{s_x}$

$$\text{porque } b = \frac{s_{xy}}{s_x^2} \frac{s_y}{s_y} = r_{(x,y)} \frac{s_y}{s_x}$$

Interpretación de los coeficientes

- ▶ Ecuación de la recta de regresión:

$$\hat{y} = a + bx$$

- ▶ a ordenada en el origen: valor medio de y cuando $x = 0$:

$$x = 0 \longrightarrow \hat{y} = a + b(0) = a$$

- ▶ b pendiente de la recta: incremento medio en y cuando se aumenta x una unidad:

$$x_2 = x_1 + 1 \longrightarrow \hat{y}_2 - \hat{y}_1 = a + b(x_1 + 1) - (a + bx_1) = b$$

Algunas veces el parámetro a carece de interpretación.

Interpretación de los coeficientes


Ejemplo: Recta de regresión ajustada para Ingresos netos (Y) en función de Años de estudio (X):

$$\hat{y} = 7667,9 + 5474,9x$$

- ▶ La renta neta media (anual) para individuos con 0 años de estudios es 7667.9 euros. En este caso, **NO** tiene sentido interpretar este parámetro.
- ▶ La renta neta media (anual) aumenta 5474.9 euros por cada año extra de estudios.

Recta de Regresión con R Commander

Ejemplo cont.



```
Ventana de resultados Ejecutar  
Call:  
lm(formula = precio ~ tamaño)  
  
Residuals:  
    Min       1Q   Median       3Q      Max  
-2.39432 -1.05972 -0.00472  0.75528  2.46308  
  
Coefficients:  
            Estimate Std. Error t value Pr(>|t|)  
(Intercept) 113.89371    4.25732   26.75 9.42e-13 ***  
tamaño      0.47260     0.04218   11.21 4.73e-08 ***  
---  
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
  
Residual standard error: 1.589 on 13 degrees of freedom  
Multiple R-squared:  0.9062, Adjusted R-squared:  0.899  
F-statistic: 125.5 on 1 and 13 DF,  p-value: 4.735e-08
```

Valores predichos, residuos y varianza residual

- ▶ Valores predichos (siempre que R^2 sea elevado y no se esté *extrapolando*):

$$\hat{y}_i = a + bx_i, \quad i = 1, \dots, n$$

- ▶ Residuos:

$$e_i = y_i - \hat{y}_i, \quad i = 1, \dots, n$$

$$\bar{e} = 0 \text{ porque } \bar{y} = \widehat{\bar{y}}.$$

- ▶ **Varianza residual**: Es una medida del error cometido en la predicción de los datos. Dividido entre $n - 2$ porque se han estimado a y b (menos dos *grados de libertad*).

$$s_e^2 = \frac{1}{n - 2} \sum_{i=1}^n e_i^2$$


- ▶ **Relación fundamental de la Regresión**: La variabilidad total de la variable dependiente se puede explicar como la suma de la variabilidad del modelo más la variabilidad residual (como sumas de cuadrados): **SCT = SCR + SCE**.

Propiedades de la recta de regresión


- ▶ Existen **dos rectas** distintas porque provienen de dos problemas de optimización diferentes:

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

$$\sum_{i=1}^n (x_i - \hat{x}_i)^2$$



$$b = \frac{s_{xy}}{s_x^2} \quad a = \bar{y} - b\bar{x}$$



$$d = \frac{s_{xy}}{s_y^2} \quad c = \bar{x} - d\bar{y}$$

Bondad del ajuste

- ▶ El **coeficiente de determinación** R^2 mide el porcentaje de la varianza total (o *información*) recogido por el modelo:

$$R^2 = \frac{SCR}{SCT} = 1 - \frac{SCE}{SCT}$$


- ▶ En el modelo de regresión lineal simple, el **Coeficiente de determinación** es igual al coeficiente de correlación al cuadrado $R^2 = r_{(x,y)}^2$
- ▶ $0 \leq R^2 \leq 1$: Mayor R^2 indica un mejor ajuste.
- ▶ Interpretación:
 - ▶ $R^2 = 1 \Rightarrow$ Ajuste perfecto ($SCE = 0$) todos los residuos son 0
 - ▶ $R^2 = 0 \Rightarrow$ Ajuste muy malo ($SCE = SCT$)
 - ▶ $R^2 < 0,6 \Rightarrow$ Modelo con escasa fiabilidad: Buscar otro modelo mejor...

Recta de Regresión: R^2 en RCommander

Ejemplo cont. Calcular e interpretar R^2 .

$$R^2 = (0,9519)^2 = 0,9061 = 90,61 \%$$

R^2 es 90.61 %, así el 90.61 % de la variabilidad muestral en el precio de las casa se explica por el tamaño.



```
Ventana de resultados Ejecutar
Call:
lm(formula = precio ~ tamaño)

Residuals:
    Min       1Q   Median       3Q      Max
-2.39432 -1.05972 -0.00472  0.75528  2.46308


Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 113.89371    4.25732   26.75 9.42e-13 ***
tamaño       0.47260    0.04218   11.21 4.73e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1.589 on 13 degrees of freedom
Multiple R-squared: 0.9062, Adjusted R-squared: 0.899
F-statistic: 125.5 on 1 and 13 DF, p-value: 4.735e-08
```

Análisis de los residuos

- ▶ Para ver si el modelo de regresión es adecuado, se hace un diagrama de dispersión de residuos frente a valores predichos.
- ▶ Un **gráfico de residuos** en el que los puntos parecen aleatorios indica que la recta de regresión se ajusta correctamente.

Ejemplo Gráfico de residuos para la recta de ingresos netos:




Los datos de *Anscombe*

Ejemplo Los datos de *Anscombe*

i	Datos 1		Datos 2		Datos 3		Datos 4	
	x	y	x	y	x	y	x	y
1	10	8,04	10	9,14	10	7,46	8	6,58
2	8	6,95	8	8,14	8	6,77	8	5,76
3	13	7,58	13	8,74	13	12,74	8	7,71
4	9	8,81	9	8,77	9	7,11	8	8,84
5	11	8,33	11	9,26	11	7,81	8	8,47
6	14	9,96	14	8,1	14	8,84	8	7,04
7	6	7,24	6	6,13	6	6,08	8	5,25
8	4	4,26	4	3,1	4	5,39	19	12,5
9	12	10,84	12	9,13	12	8,15	8	5,56
10	7	4,82	7	7,26	7	6,42	8	7,91
11	5	5,68	5	4,74	5	5,73	8	6,89

- ▶ Los datos de *Anscombe* son cuatro conjuntos de datos de dos variables cada uno. Estos conjuntos de datos son distintos pero la recta de regresión que determinan es la misma.
- ▶ Nos muestran la necesidad de observar los datos antes de interpretar la recta de regresión.

Los datos de *Anscombe*



Los datos de *Anscombe*

- ▶ Recta ajustada:

$$\hat{y} = 3 + 0,5x$$

- ▶ **Interpretación de la pendiente:** un incremento de una unidad en la variable X produce, **en promedio**, un incremento de **0.5** unidades en la variable Y .
- ▶ **Predicción para $x = 7,5$ (dentro del rango de X)**

$$\hat{y} = 3 + 0,5(7,5) = 6,75$$