Estadística II

TEMA 2. DISTRIBUCIÓN DE PROBABILIDADES BIDIMENSIONAL

Marta Guijarro Garvi
David Gutiérrez Sobrao

DEPARTAMENTO DE ECONOMÍA

Este material se publica bajo licencia:

[Creative Commons BY-NC-SA 4.0](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Tema 2: Distribución de probabilidades bidimensional

Índice de contenidos

- Distribución de probabilidades bidimensional: función de distribución conjunta.
- Variable aleatoria bidimensional discreta.
- Variable aleatoria bidimensional continua.
- Distribuciones condicionadas: funciones de probabilidad y de densidad condicionadas y esperanzas condicionadas.
- Independencia.
- Regresión lineal: rectas de regresión y bondad del ajuste.

Tema 2: Distribución de probabilidades bidimensional

Resultados de aprendizaje

- Entender el concepto de distribución de probabilidades bidimensional a partir del concepto de distribución de frecuencias bidimensional.
- Conocer las semejanzas y diferencias entre variables aleatorias discretas y continuas.
- Saber hallar distribuciones marginales y condicionadas.
- Comprender la naturaleza unidimensional de las distribuciones condicionadas.
- Saber calcular probabilidades a partir de distribuciones marginales y condicionadas.
- Conocer la diferencia entre incorrelación e independencia.
- Saber hallar las rectas de regresión y calcular e interpretar la bondad de los ajustes.

Distribución de probabilidades bidimensional: función de distribución conjunta

Una **variable aleatoria bidimensional** es un par (X, Y) en el que X e Y son variables aleatorias.

La distribución de probabilidades de una variable aleatoria bidimensional o **distribución de probabilidades bidimensional** está determinada por la función de distribución de la variable bidimensional (X, Y) o **función de distribución conjunta**:

$$F_{X,Y}(x, y) = p[X \leq x, Y \leq y] \quad \forall x, y \in \mathbb{R}.$$

Variable aleatoria bidimensional discreta

Una **variable aleatoria bidimensional discreta** es un par (X, Y) en el que X e Y son variables aleatorias discretas.

La distribución de probabilidades de una variable bidimensional discreta (X, Y) queda determinada por su función de probabilidad o **función de probabilidad conjunta**:

$$f_{X,Y}(x, y) = p[X = x, Y = y] \quad \forall x, y \in \mathbb{R}.$$

Además,

- Para todo par de números reales, x e y , se cumple que $0 \leq f_{X,Y}(x, y) \leq 1$.
- $\sum_{i=1}^{\infty} \sum_{j=1}^{\infty} f_{X,Y}(x_i, y_j) = 1$, donde x_i ($i = 1, \dots$) e y_j ($j = 1, \dots$) son los valores que toman X e Y , respectivamente.

Las funciones de probabilidad de las variables X e Y o **funciones de probabilidad marginales** son, respectivamente,

$$f_X(x_i) = \sum_{j=1}^{\infty} f_{X,Y}(x_i, y_j) \quad \text{y} \quad f_Y(y_j) = \sum_{i=1}^{\infty} f_{X,Y}(x_i, y_j).$$

Variable aleatoria bidimensional continua

Una **variable aleatoria bidimensional continua** es una variable aleatoria (X, Y) cuya función de distribución, $F_{X,Y}(x, y)$, cumple las siguientes condiciones:

- Es continua en cada variable.
- Existen sus dos primeras derivadas parciales, así como su segunda derivada respecto a ambas variables, la cual es continua salvo, a lo sumo, en un número finito de curvas.
- $$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{\partial^2}{\partial x \partial y} F_{X,Y}(x, y) dy dx = 1.$$

Variable aleatoria bidimensional continua

La distribución de probabilidades de una variable aleatoria bidimensional continua (X, Y) queda determinada por su función de densidad bidimensional o **función de densidad conjunta**:

$$f_{X,Y}(x, y) = \frac{\partial^2}{\partial x \partial y} F_{X,Y}(x, y) \quad \forall x, y \in \mathbb{R}.$$

Además,

- Para todo par de números reales, x e y , se cumple que $f_{X,Y}(x, y) \geq 0$.
- $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy dx = 1$.

Las funciones de densidad de las variables X e Y o **funciones de densidad marginales** son, respectivamente,

$$f_X(x) = \int_{y=-\infty}^{\infty} f_{X,Y}(x, y) dy \quad y \quad f_Y(y) = \int_{x=-\infty}^{\infty} f_{X,Y}(x, y) dx$$

Distribuciones condicionadas: funciones de probabilidad condicionadas

Dada una variable aleatoria bidimensional discreta (X, Y) , las **distribuciones de probabilidades condicionadas** quedan determinadas por las **funciones de probabilidad condicionadas**, tal y como se recoge en la siguiente tabla.

<i>Distribuciones de X condicionadas por los valores que toma Y</i>	<i>Distribuciones de Y condicionadas por los valores que toma X</i>
<p>Función de probabilidad de X condicionada por $Y = y_j$:</p> $f_{X/Y=y_j}(x) = \frac{f_{X,Y}(x, y_j)}{f_Y(y_j)} \quad \forall x \in \mathbb{R} \quad f_Y(y_j) \neq 0$	<p>Función de probabilidad de Y condicionada por $X = x_i$:</p> $f_{Y/X=x_i}(y) = \frac{f_{X,Y}(x_i, y)}{f_X(x_i)} \quad \forall y \in \mathbb{R} \quad f_X(x_i) \neq 0$

Distribuciones condicionadas: funciones de probabilidad condicionadas

Ejemplo 2.1. La distribución conjunta y las marginales de X e Y aparecen en la siguiente tabla:

$X \setminus Y$	0	3	
1	0,2	0,3	0,5
2	0,1	0,4	0,5
	0,3	0,7	

Estas distribuciones permiten hallar las distribuciones condicionadas, las cuales quedan determinadas mediante las correspondientes funciones de probabilidad condicionadas que figuran en la tabla siguiente.

<i>Distribuciones de X condicionadas por los valores que toma Y</i>	<i>Distribuciones de Y condicionadas por los valores que toma X</i>
$f_{X/Y=0}(x) = \begin{cases} \frac{f_{X,Y}(1,0)}{f_Y(0)} = \frac{2}{3} & x=1 \\ \frac{f_{X,Y}(2,0)}{f_Y(0)} = \frac{1}{3} & x=2 \\ 0 & \text{en el resto} \end{cases}$	$f_{Y/X=1}(y) = \begin{cases} \frac{f_{X,Y}(1,0)}{f_X(1)} = \frac{2}{5} & y=0 \\ \frac{f_{X,Y}(1,3)}{f_X(1)} = \frac{3}{5} & y=3 \\ 0 & \text{en el resto} \end{cases}$
$f_{X/Y=3}(x) = \begin{cases} \frac{f_{X,Y}(1,3)}{f_Y(3)} = \frac{3}{7} & x=1 \\ \frac{f_{X,Y}(2,3)}{f_Y(3)} = \frac{4}{7} & x=2 \\ 0 & \text{en el resto} \end{cases}$	$f_{Y/X=2}(y) = \begin{cases} \frac{f_{X,Y}(2,0)}{f_X(2)} = \frac{1}{5} & y=0 \\ \frac{f_{X,Y}(2,3)}{f_X(2)} = \frac{4}{5} & y=3 \\ 0 & \text{en el resto} \end{cases}$

Distribuciones condicionadas: funciones de densidad condicionadas

Dada una variable aleatoria bidimensional continua (X, Y) las **distribuciones de probabilidades condicionadas** quedan determinadas por las **funciones de densidad condicionadas**, tal y como se recoge en la siguiente tabla.

<i>Distribuciones de X condicionadas por los valores que toma Y</i>	<i>Distribuciones de Y condicionadas por los valores que toma X</i>
<p>Función de densidad de X condicionada por $Y = y$:</p> $f_{X/Y=y}(x) = \frac{f_{X,Y}(x, y)}{f_Y(y)} \quad \forall x \in \mathbb{R} \quad f_Y(y) \neq 0$	<p>Función de densidad de Y condicionada por $X = x$:</p> $f_{Y/X=x}(y) = \frac{f_{X,Y}(x, y)}{f_X(x)} \quad \forall y \in \mathbb{R} \quad f_X(x) \neq 0$

Distribuciones condicionadas: funciones de densidad condicionadas

Ejemplo 2.2. La función de densidad conjunta de X e Y es:

$$f_{X,Y}(x,y) = \begin{cases} 1 & 1 < x < 2, 1 < y < 2 \\ 0 & \text{en el resto} \end{cases}$$

Con esta función de densidad conjunta se obtienen las funciones de densidad marginales de X e Y :

$$f_Y(y) = \int_{x=-\infty}^{\infty} f_{X,Y}(x,y) dx = \int_{x=1}^2 1 dx = 1 \quad 1 < y < 2 \quad f_X(x) = \int_{y=-\infty}^{\infty} f_{X,Y}(x,y) dy = \int_{y=1}^2 1 dy = 1 \quad 1 < x < 2$$

Las funciones de densidad conjunta y marginales permiten hallar las distribuciones condicionadas, las cuales quedan determinadas por las correspondientes funciones de densidad condicionadas recogidas en la tabla siguiente.

<i>Distribuciones de X condicionadas por los valores que toma Y</i>	<i>Distribuciones de Y condicionadas por los valores que toma X</i>
Para $1 < y < 2$ $f_{X/Y=y}(x) = \frac{f_{X,Y}(x,y)}{f_Y(y)} = \frac{1}{1} = 1 \quad 1 < x < 2$	Para $1 < x < 2$ $f_{Y/X=x}(y) = \frac{f_{X,Y}(x,y)}{f_X(x)} = \frac{1}{1} = 1 \quad 1 < y < 2$

Distribuciones condicionadas: esperanzas condicionadas

Dada una variable aleatoria bidimensional (X, Y) las esperanzas condicionadas son las esperanzas de las correspondientes distribuciones condicionadas, tal y como se recoge en la siguiente tabla para variables bidimensionales discretas y continuas.

Variable aleatoria bidimensional discreta (distribución de probabilidades bidimensional discreta)	
<i>Distribuciones de X condicionadas por los valores que toma Y</i>	<i>Distribuciones de Y condicionadas por los valores que toma X</i>
Esperanza de X condicionada por $Y = y_j$: $E(X/Y = y_j) = \sum_{i=1}^{\infty} x_i \cdot f_{X/Y=y_j}(x_i)$	Esperanza de Y condicionada por $X = x_i$: $E(Y/X = x_i) = \sum_{j=1}^{\infty} y_j \cdot f_{Y/X=x_i}(y_j)$
Variable aleatoria bidimensional continua (distribución de probabilidades bidimensional continua)	
<i>Distribuciones de X condicionadas por los valores que toma Y</i>	<i>Distribuciones de Y condicionadas por los valores que toma X</i>
Esperanza de X condicionada por $Y = y$: $E(X/Y = y) = \int_{-\infty}^{\infty} x \cdot f_{X/Y=y}(x) dx$	Esperanza de Y condicionada por $X = x$: $E(Y/X = x) = \int_{-\infty}^{\infty} y \cdot f_{Y/X=x}(y) dy$

Distribuciones condicionadas: esperanzas condicionadas

Ejemplo 2.3 (continuación del Ejemplo 2.1) Las esperanzas de las distribuciones condicionadas (esperanzas condicionadas) son:

$$\begin{aligned} E(X/Y = 0) &= \sum_{i=1}^{\infty} x_i \cdot f_{X/Y=0}(x_i) = \frac{4}{3} & E(X/Y = 3) &= \sum_{i=1}^{\infty} x_i \cdot f_{X/Y=3}(x_i) = \frac{11}{7} \\ E(Y/X = 1) &= \sum_{j=1}^{\infty} y_j \cdot f_{Y/X=1}(y_j) = \frac{9}{5} & E(Y/X = 2) &= \sum_{j=1}^{\infty} y_j \cdot f_{Y/X=2}(y_j) = \frac{12}{5} \end{aligned}$$

Ejemplo 2.4 (continuación del Ejemplo 2.2) La esperanza de la distribución de X condicionada, por ejemplo, por $Y = 1,3$ es

$$E(X/Y = 1,3) = \int_{-\infty}^{\infty} x \cdot f_{X/Y=1,3}(x) dx = \int_{x=1}^2 x \cdot 1 dx = 1,5.$$

$$\text{con } f_{X/Y=1,3}(x) = 1 \quad 1 < x < 2.$$

La esperanza de la distribución de Y condicionada, por ejemplo, por $X = 1,8$ es

$$E(Y/X = 1,8) = \int_{-\infty}^{\infty} y \cdot f_{Y/X=1,8}(y) dy = \int_{y=1}^2 y \cdot 1 dy = 1,5.$$

$$\text{con } f_{Y/X=1,8}(y) = 1 \quad 1 < y < 2.$$

Independencia

Sea (X, Y) una variable aleatoria bidimensional. Las variables X e Y son **independientes** si

$$f_{X,Y}(x, y) = f_X(x) \cdot f_Y(y) \quad \forall x, y \in \mathbb{R},$$

siendo $f_{X,Y}(x, y)$, $f_X(x)$ y $f_Y(y)$ funciones de probabilidad o de densidad, dependiendo de si la variable bidimensional es discreta o continua.

Además, es condición necesaria y suficiente para que las variables X e Y sean independientes que las distribuciones condicionadas coincidan con las correspondientes marginales.

Así, cuando (X, Y) es una variable bidimensional discreta, X e Y son independientes si y solamente si:

$$f_{X/Y=y_j}(x) = f_X(x) \quad \forall x \in \mathbb{R} \quad (f_Y(y_j) \neq 0) \quad \text{y} \quad f_{Y/X=x_i}(y) = f_Y(y) \quad \forall y \in \mathbb{R} \quad (f_X(x_i) \neq 0).$$

Y, cuando (X, Y) es continua, X e Y son independientes si y solamente si:

$$f_{X/Y=y}(x) = f_X(x) \quad \forall x \in \mathbb{R} \quad (f_Y(y) \neq 0) \quad \text{y} \quad f_{Y/X=x}(y) = f_Y(y) \quad \forall y \in \mathbb{R} \quad (f_X(x) \neq 0).$$

Regresión lineal: rectas de regresión

Sea (X, Y) una variable aleatoria bidimensional. La **covarianza** entre X e Y es

$$\text{Cov}(X, Y) = E[(X - \mu_X) \cdot (Y - \mu_Y)].$$

Se cumple: $\text{Cov}(X, Y) = E(X \cdot Y) - \mu_X \cdot \mu_Y$

La recta que mejor explica¹ la variable Y en función de la variable X es la **recta de regresión de Y sobre X** :

$$y = \mu_Y + \frac{\text{Cov}(X, Y)}{\sigma_X^2} \cdot (x - \mu_X).$$

Análogamente, la recta que mejor explica la variable X en función de la variable Y es la **recta de regresión de X sobre Y** :

$$x = \mu_X + \frac{\text{Cov}(X, Y)}{\sigma_Y^2} \cdot (y - \mu_Y).$$

¹El criterio utilizado para obtener las rectas de regresión es el de los mínimos cuadrados.

Los coeficientes de regresión de las rectas de regresión son: $\beta_{Y/X} = \text{Cov}(X, Y) / \sigma_X^2$ y $\beta_{X/Y} = \text{Cov}(X, Y) / \sigma_Y^2$.

Tema 2. Distribución de probabilidades bidimensional

Regresión lineal: bondad de ajuste

La evaluación de la calidad de la explicación lineal obtenida mediante las rectas de regresión, esto es, el análisis de la **bondad de ajuste** se realiza con el **coeficiente de correlación**:

$$\rho = \frac{Cov(X, Y)}{\sigma_X \cdot \sigma_Y} \quad (-1 \leq \rho \leq 1),$$

y mediante su cuadrado, el **coeficiente de determinación lineal**:

$$\rho^2 = \frac{[Cov(X, Y)]^2}{\sigma_X^2 \cdot \sigma_Y^2} \quad (0 \leq \rho^2 \leq 1).$$

- Si ρ es igual a -1 o a 1 ($\rho^2 = 1$), el ajuste es perfecto (negativo o positivo, respectivamente), existiendo una relación lineal exacta negativa o positiva entre las variables.
- Si ρ es igual a 0 ($\rho^2 = 0$), el ajuste es pésimo, no existiendo relación lineal entre ellas. En este caso, las variables están **incorrelacionadas**.
- El signo de las pendientes de las rectas de regresión, de los coeficientes de regresión y del coeficiente de correlación es el signo de la covarianza.
- Si dos variables son independientes están incorrelacionadas, pero el recíproco no es cierto.

Regresión lineal: rectas de regresión y bondad del ajuste

Ejemplo 2.5. La distribución conjunta y las distribuciones marginales de X e Y se presentan en la siguiente tabla:

$X \setminus Y$	0	1	2	
1	0,05	0,09	0	0,14
2	0,10	0,16	0,22	0,48
3	0,16	0,10	0,12	0,38
	0,31	0,35	0,34	

Las medias y varianzas de X e Y , así como la covarianza entre ellas son:

$$E(X) = \sum_{i=1}^{\infty} x_i \cdot f_X(x_i) = 2,240 \quad \text{Var}(X) = \sum_{i=1}^{\infty} (x_i - \mu_X)^2 \cdot f_X(x_i) = 0,462$$

$$E(Y) = \sum_{j=1}^{\infty} y_j \cdot f_Y(y_j) = 1,030 \quad \text{Var}(Y) = \sum_{j=1}^{\infty} (y_j - \mu_Y)^2 \cdot f_Y(y_j) = 0,649$$

$$\text{Cov}(X, Y) = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} (x_i - \mu_X) \cdot (y_j - \mu_Y) \cdot f_{X,Y}(x_i, y_j) = 0,003$$

En consecuencia, las rectas de regresión de Y sobre X y de X sobre Y son, respectivamente:

$$y = 0,006 \cdot x + 1,016 \quad \text{y} \quad x = 0,004 \cdot y + 2,236.$$

Además, los coeficientes de correlación y determinación lineal son:

$$\rho = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y} = 0,005 \quad \text{y} \quad \rho^2 \simeq 0.$$

Las rectas de regresión, casi paralelas a los ejes de coordenadas, junto con los valores de los coeficientes, evidencian la casi inexistente relación lineal entre las variables.