

# Apuntes Estadística

Fernando Parra

3 de mayo de 2014

## 1. Variables aleatorias bidimensionales

### 1.1. Variables aleatoria bidimensionale

### 1.2. Distribución bidimensional discreta

**Definición** Sea  $(X, Y)$  una variable aleatoria bidimensional discreta con rango  $R_{X \times Y}$ . A cada posible resultado  $(x, y)$  de  $(X, Y)$ , asociamos un número

$$p(x, y) = P[X = x, Y = y]$$

llamado la *función de probabilidad conjunta*, que cumple las siguientes condiciones

1.  $p(x, y) \geq \forall(x, y)$
2.  $\sum_{(x, y) \in R_{X \times Y}} p(x, y) = 1$

Los valores  $[(x, y), p(x, y)]$  para todo  $(x, y) \in R_{X \times Y}$ , se llama la *distribución de probabilidad conjunta*. La probabilidad de un evento cualquiera  $A$  en  $R_{X \times Y}$  ( $A \subset R_{X \times Y}$ ), está definido por

$$P[(X, Y) \in A] = \sum_{(x, y) \in A} p(x, y)$$

Como en el caso unidimensional, la distribución de probabilidad conjunta de  $(X, Y)$  es inducida por la probabilidad de los sucesos del espacio muestral original  $\Sigma$ . Si la variable aleatoria bidimensional es finita, la distribución de probabilidad conjunta se representa en una tabla co dos entradas como se muestra en esta tabla.

$y \backslash x$	$x_1$	$x_2$	$\dots$	$x_n$
$y_1$	$p(x_1, y_1)$	$p(x_2, y_1)$	$\dots$	$p(x_n, y_1)$
$y_2$	$p(x_1, y_2)$	$p(x_2, y_2)$	$\dots$	$p(x_n, y_2)$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$y_m$	$p(x_1, y_m)$	$p(x_2, y_m)$	$\dots$	$p(x_n, y_m)$

**Definición** La *función de distribución acumulada* de la variable aleatoria bidimensional está definida por

$$F(x, y) = P[X \leq x, Y \leq y] = \sum_{u=-\infty}^x \sum_{v=-\infty}^y p(u, v)$$

#### 1.2.1. Distribuciones marginales

En algunos casos se puede estar interesado solo en las distribuciones de  $X$  o de  $Y$ .

**Definición** La función de probabilidad individual para  $X$  e  $Y$  se llaman *distribuciones de probabilidad marginal o funciones de probabilidad marginal*. La distribución marginal para  $X$ , está dado por

$$p_X(x) = P[X = x] = \sum_{y \in R_Y | X=x} P[X = x, Y = y] = \sum_{y \in R_Y | X=x} p(x, y)$$

donde  $y \in R_Y | X = x$  es el rango de valores para  $Y$ , dado que  $X = x$ , note que este rango puede ser diferente para valores diferentes de  $x$ .

La *distribución marginal* para  $Y$ , esta dada por

$$p_Y(y) = P[Y = y] = \sum_{x \in R_X | Y=y} p(x, y)$$

El nombre marginal se debe a que los valores de estas distribuciones están dadas por la suma total en los márgenes de las filas y columnas de la representación tabular de  $p(x, y)$ .

### 1.2.2. Variables aleatorias independientes

El concepto de independencia de variables aleatorias es muy importante en estadística. Como en el caso de independencia de eventos intuitivamente diremos que las variables aleatorias  $X$  e  $Y$  son *independientes* si el resultado de una de las variables, digamos  $X$  no influye en el resultado de  $Y$ , y viceversa.

**Definición** Sean  $(X, Y)$  una variable aleatoria bidimensional discreta con función de probabilidad marginal  $p_X(x)$  y  $p_Y(y)$ . Se dice que  $X$  e  $Y$  son independientes si, solo si

$$p(x, y) = p_X(x)p_Y(y), \quad \forall(x, y)$$

o que  $P[X = x, Y = y] = P[X = x] \cdot P[Y = y]$ ,  $\forall(x, y)$ . En otras palabras,  $X$  e  $Y$  son independientes si,  $P[X = x]$  no afecta a la  $P[Y = y]$ .

### 1.2.3. Distribución de probabilidad condicional

Dado dos eventos  $A$  y  $B$ , la probabilidad condicional de que ocurra el evento  $A$  dado que ha ocurrido el evento  $B$ . Extenderemos este concepto a la distribución condicional de una variable aleatoria  $X$ , dado que la variable aleatoria  $Y$  haya tomado un valor determinado, por ejemplo  $y_0$ .

Sea  $(X, Y)$  un avariable aleatoria bidimensional con función de probabilidad  $p(x, y)$  de rango  $R_{X \times Y}$ , y probabilidad marginales es  $p_X(x)$ ,  $p_Y(y)$ .  $R_X$  y  $R_Y$  los rangos de las variables aleatorias  $X$  e  $Y$  respectivamente.

Sean los eventos  $A = (X = x)$ ,  $B = (Y = y)$ ,  $(x, y) \in R_{X \times Y}$ , entonces, por la definición de probabilidad condicional se tiene.

$$P[A|B] = \frac{P[A \cap B]}{P[B]}$$

Pero,  $A \cap B = (X = x, Y = y)$ , por lo tanto  $P[A \cap B] = P[X = x, Y = y] = p(x, y)$  y  $P[B] = P[Y = y] = p_Y(y) > 0$ , pues  $y \in R_Y$ .

Luego, la probabilidad condicional del evento  $A$ , dado  $B$  es

$$P[A|B] = \frac{P[A \cap B]}{P[B]} = \frac{p[X = x, Y = y]}{P[Y = y]} = \frac{p(x, y)}{p_Y(y)}$$

Es decir

$$P[X = x|Y = y] = \frac{p[X = x, Y = y]}{P[Y = y]} = \frac{p(x, y)}{p_Y(y)}$$

La razón  $\frac{p(x, y)}{p_Y(y)}$ , se llama la función de *probabilidad condicional* de  $X$ , dado  $Y = y$ . La siguiente definición formaliza lo expuesto en el párrafo anterior.

**Definición** Si  $(X, Y)$  es una variable aleatoria bidimensional discreta, la *función de probabilidad condicional* de  $X$  dado  $Y = y$ , se denota por  $p_{X|Y}(x|y)$  y se define por

$$p_{X|Y}(x|y) = \frac{p(x, y)}{p_Y(y)}, \quad p_Y(y) > 0$$

Similarmente, la *función de probabilidad condicional* de  $Y$  dado  $X = x$ , se define por

$$p_{Y|X}(y|x) = \frac{p(x, y)}{p_X(x)}, \quad p_X(x) > 0$$

Notamos que  $p_{X|Y}(x|y) > 0$ .

$$\sum_{x \in R_X|Y=y} p_{X|Y}(x|y) = \sum_{x \in R_X|Y=y} \frac{p(x, y)}{p_Y(y)} = \frac{\sum_{x \in R_X|Y=y} p(x, y)}{p_Y(y)} = \frac{p_Y(y)}{p_Y(y)} = 1$$

Es decir,  $p_{X|Y}(x|y)$  cumple las condiciones de una función de probabilidad, entonces se puede calcular probabilidades tales como

$$P[a \leq X \leq b|Y = y] = \sum_{x \in R_X|a \leq x \leq b} p_{X|Y}(x|y)$$

$$P[X < a|Y = y] = \sum_{x \in R_X|a < x} p_{X|Y}(x|y)$$

**Teorema** Sea  $(X, Y)$  una variable aleatoria bidimensional, entonces

$$p_{X|Y}(x|y) = p_X(x), \quad \forall(x, y)$$

$$p_{Y|X}(y|x) = p_Y(y), \quad \forall(x, y)$$

si solo si  $X$  e  $Y$  son variables aleatorias independientes.

#### 1.2.4. Esperanza y varianza

En algunos problemas, se requiere calcular, el valor esperado de una función de dos o más variables aleatorias  $X$  e  $Y$ , por ejemplo:  $X + Y$ ,  $XY$ ,  $X^2Y + X$ . La técnica para obtener el valor esperado de una función de dos variables aleatorias es la misma que en el caso de una variables, como indica la definición siguiente.

**Definición** Sea  $(X, Y)$  una variable aleatoria bidimensional discreta, y  $H(X, Y)$  una función de dos variables aleatorias  $X$  e  $Y$ . El *valor esperado* de  $H(X, Y)$ , se define por

$$E[H(X, Y)] = \sum_{R_X \times Y} \sum H(x, y)p(x, y)$$

Siempre que la suma sea absolutamente convergente. En el caso particular de que  $H(X, Y) = X$ , se tiene

$$\mu_X = E(X) = \sum_{R_X \times Y} \sum xp(x, y) = \sum_{x \in R_X} x \sum_{y \in R_Y} p(x, y) = \sum_{x \in R_X} xp_X(x)$$

Similarmente, si  $H(X, Y) = Y$ ,  $\mu_Y = E(Y) = \sum_{y \in R_Y} yp_Y(y)$ . Es decir, la media de  $X(Y)$ , se determina, de la función de probabilidad marginal de  $X(Y)$ . El lector, siguiendo un proceso similar, puede encontrar que la varianza de  $X$  y de  $Y$  están dados por

$$\sigma_X^2 = E(X - \mu_X)^2 = \sum_{x \in R_X} (x - \mu_X)^2 p_X(x) = E(X^2) - (\mu_X)^2$$

$$\sigma_Y^2 = E(Y - \mu_Y)^2 = \sum_{y \in R_Y} (y - \mu_Y)^2 p_Y(y) = E(Y^2) - (\mu_Y)^2$$

observe que

$$H(X, Y) = (X - \mu_X)^2; \quad H(X, Y) = (Y - \mu_Y)^2$$

**Teorema** Si  $(X, Y)$  es una variable aleatoria bidimensional, entonces

$$E[aH(x) \pm bG(Y)] = aE[H(X)] \pm bE[G(Y)]$$

una secuencia inmediata de este teorema, cuando

$$H(X) = X, \text{ y } G(Y) = Y, \text{ es: } E(X \pm Y) = E(X) \pm E(Y)$$

**Teorema** Si  $X$  e  $Y$  son dos variables aleatorias independientes, entonces

1.  $E(XY) = E(X)E(Y)$
2.  $Var(X + Y) = Var(X) + Var(Y)$

Una generalización de 1. de este teorema es la siguiente. Si  $X$  e  $Y$  son variables aleatorias independientes y  $H(X)$ ,  $G(Y)$  son funciones de  $X$  e  $Y$  respectivamente, entonces

$$E[H(X)G(Y)] = E[H(X)]E[G(Y)]$$

También 2. se puede generalizar a  $n$  variables aleatorias.

### 1.2.5. Esperanza condicional

### 1.2.6. Covarianza y coeficientes de correlación

Daremos la definición de unos números que miden como, están relacionados los valores posible de  $X$  con los valores posibles de  $Y$ ; estos números dependen de la función de probabilidad conjunto de  $X$  e  $Y$ .

**Definición** Sean  $X$  e  $Y$  dos variables aleatorias con media  $\mu_X$  y  $\mu_Y$ , respectivamente. La *covarianza* de  $X$  e  $Y$ , denotado por  $Cov(X, Y)$ ,  $\sigma_{XY}$ , se define por

$$Cov(X, Y) = \sigma_{XY} = E[(X - \mu_X)(Y - \mu_Y)] = \sum_{(x,y) \in R_{X \times Y}} (x - \mu_X)(y - \mu_Y)p(x, y)$$

A diferencia de la varianza que siempre es no negativa, la covarianza puede ser negativa, cero o positiva. Si los valores más pequeños de  $X$  son asociados con valores grandes  $Y$ , y viceversa, entonces la covarianza es negativa. Es decir, si  $X - \mu_x$  e  $Y - \mu_y$  tienen signos opuestos. En cambio la covarianza será positiva cuando los valores grandes de  $X$ , se asocian con valores grandes de  $Y$ , y valores pequeños de  $X$  son asociados con valores pequeños aunque pueden ser dependientes. Una fórmula alternativa para calcular covarianzas, da el siguiente teorema.

**Teorema** La *covarianza* de dos variables aleatorias  $X$  e  $Y$ , con media  $\mu_X$  y  $\mu_Y$  respectivamente, está dado por

$$Cov(X, Y) = E(XY) - \mu_X\mu_Y$$

**Teorema** Si  $X$  e  $Y$  son variables aleatorias independientes, entonces

$$Cov(X, Y) = 0$$

**Teorema** Si  $X$  e  $Y$  son variables aleatorias con función de probabilidad conjunta y varianzas finitas, entonces

$$Var(aX \pm bY) = a^2Var(X) + b^2Var(Y) \pm 2abCov(X, Y)$$

**Definición** Sean  $X$  e  $Y$  variables aleatorias con desviación estándar  $\sigma_X$  y  $\sigma_Y$  respectivamente. El *coeficiente de correlación* de  $X$  e  $Y$ , denotado  $\rho(X, Y)$ , se define por

$$\rho(X, Y) = \frac{Cov(X, Y)}{\sigma_X\sigma_Y}$$

**Teorema** Propiedades del coeficiente de correlación  $\rho$

1.  $-1 \leq \rho \leq 1$
2.  $\rho(X, Y) = \rho(Y, X)$
3. Si  $X$  e  $Y$  son independientes, entonces  $\rho = 0$
4. Si  $\rho = \pm 1$ , entonces entre  $X$  e  $Y$  existe una dependencia funcional lineal.
5. Suponga que  $Y = aX + b$ , donde  $a$  y  $b$  son constantes.  
Si  $a > 0$ , entonces  $\rho(X, Y) = 1$ ; si  $a < 0$ , entonces  $\rho(X, Y) = -1$
6. Si  $a, b, c, d$  son constantes,  $a > 0$  y  $b > 0$ , entonces  $\rho(aX + c, bY + d) = \rho(X, Y)$

### 1.3. Distribuciones bidimensionales continuas

**Definición** Si  $(X, Y)$  es una variable bidimensional continua. La función de densidad de probabilidad conjunta, es una función integrable  $f(x, y)$  que cumple las siguientes propiedades:

1.  $f(x, y) > 0, \quad \forall(x, y)$
2.  $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) dx dy = 1$

La probabilidad de un evento  $A$  definido en un plano euclideo, está dado por

$$P[(X, Y) \in A] = \iint_A f(x, y) dx dy$$

Y por tanto  $P[(X, Y) \in A]$  es el volumen del sólido sobre la región  $A$  es el plano  $XY$  y acotado por la superficie  $f(x, y)$ .

Las funciones de Densidad Marginal son:

1.  $f_X(x) = \int_{-\infty}^{+\infty} f(x, y) dx$ , función densidad marginal para  $X$ .
2.  $f_Y(y) = \int_{-\infty}^{+\infty} f(x, y) dy$ , función densidad marginal para  $Y$ .

El valor esperado de  $X$  (media de  $X$ ), el valor esperado de  $Y$  (o media de  $Y$ ) están dados por

$$E(X) = \mu_X = \int_{-\infty}^{+\infty} x f_X(x) dx = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x f(x, y) dy dx$$

$$E(Y) = \mu_Y = \int_{-\infty}^{+\infty} y f_Y(y) dy = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} y f(x, y) dy dx$$

En general, el valor esperado de una función  $H(X, Y)$  se define por

$$E[H(X, Y)] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} H(x, y) f(x, y) dx dy$$

Las propiedades son las mismas que en el caso discreto, entonces

$$E[H(X, Y) \pm G(X, Y)] = E[H(X, Y)] \pm E[G(X, Y)]$$

La varianza de  $X$  e  $Y$  están definidos como sigue

$$Var(X) = \sigma_X^2 = \int_{-\infty}^{+\infty} (x - \mu_X)^2 f_X(x) dx = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - \mu_X)^2 f(x, y) dy dx$$

$$Var(Y) = \sigma_Y^2 = \int_{-\infty}^{+\infty} (y - \mu_Y)^2 f_Y(y) dy = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (y - \mu_Y)^2 f(x, y) dy dx$$

También

$$\sigma_X^2 = E(X^2) - (\mu_X)^2$$

## 2. Función de distribución binomial y poissoniana

### 2.1. Ensayo de Bernoulli

Hay muchos experimentos que tienen o los dos resultados posibles, llamados *éxito*  $E$  y *fracaso*  $F$ . Luego, el espacio muestral para este tipo de ensayo es  $\Omega = \{E, F\}$ .

Un experimento con esta característica se llama un *ensayo de Bernoulli*. Definimos la variable aleatoria  $X$  de tal manera que  $X(w) =$  número de éxitos en un ensayo de Bernoulli.  $R_X = \{0, 1\}$

Es decir:  $X(F) = 0$ , “si el resultado del ensayo es una  $F$ ” y  $X(E) = 1$ , “si el resultado del ensayo es una  $E$ ”.

La variable aleatoria  $X$ , así definida se llama, *variable aleatoria de Bernoulli*.

Denotemos  $p = P[E]$  y  $q = 1 - p = P[F]$ .

La distribución de probabilidad de la variable aleatoria  $X$  de Bernoulli, es llamada *distribución de Bernoulli*

La distribución de Bernoulli se escribe también como una función así,

$$p(x) = P[X = x] = p^x(1 - p)^{1-x}, \quad x = 0 \text{ ó } x = 1$$

La media y la varianza de la variable aleatoria  $X$ , se calcula como sigue:

$$\begin{aligned} \mu &= E(x) = 0 \cdot q + 1 \cdot p = p \\ \sigma_X^2 &= Var(X) = E(X^2) - (E(X))^2 \\ &= 0^2 \cdot q + 1^2 \cdot p - p^2 = p - p^2 = p(1 - p) \\ &= pq \end{aligned}$$

Hay muchos problemas en los que el experimento consiste de  $n$  ensayos de Bernoulli. Se dice que una secuencia de  $n$  ensayos iguales de Bernoulli, forman un *proceso de Bernoulli* o *proceso binomial*.

### 2.2. Distribución binomial

Es el resultado de un experimento aleatorio con las siguientes características:

1. Los resultados posibles son 2:  $A$  o  $\bar{A}$
2. La probabilidad de  $A$  es constante,  $P[A] = p$ .
3. Las pruebas son independientes.
4. Debo definir el número total de pruebas.

La *distribución binomial* de la variable aleatoria  $X$  es

$$P[X = x|B; n, p] = P[X = x] = \binom{n}{x} p^x q^{n-x}, \quad x = 0, 1, 2, \dots, n$$

Algunas veces, escribiremos simplemente

$$b(x; n, p) = \binom{n}{x} p^x q^{n-x}, \quad x = 0, 1, 2, \dots, n$$

Observe que:

1.  $p(x) = P[X = x] > 0$ ,  $x = 0, 1, 2, \dots, n$
2.  $\sum_{x=0}^n p(x) = \sum_{x=0}^n P[X = x] = \sum_{x=0}^n \binom{n}{x} p^x q^{n-x} = (p + q)^n = 1 = 1$ , ya que  $p + q = 1$ .

La función de *distribución acumulada* está dada por

$$F(x) = P[X \leq x] = P[X \leq x|B; n, p] = \begin{cases} 0 & , x < 0 \\ \sum_{k=0}^{\lfloor x \rfloor} \binom{n}{k} p^k q^{n-k} & , 0 \leq x < n \\ 1 & , x \geq n \end{cases}$$

### 2.2.1. Características de la distribución binomial

La media de la variable aleatoria binomial se puede calcular utilizando directamente la definición.

$$\begin{aligned}\mu = E(X) &= \sum_{x=0}^n x \binom{n}{x} p^x q^{n-x} = \sum_{x=0}^n x \frac{n!}{x!(n-x)!} p^x q^{n-x} \\ &= \sum_{x=0}^n \frac{n(n-1)!}{(x-1)!(n-x)!} p^x q^{n-x} \\ &= np \sum_{x=0}^n \frac{(n-1)!}{(x-1)!(n-x)!} p^{x-1} q^{n-x}\end{aligned}$$

Cambiando el índice de la suma,  $l = x - 1$ , se tiene

$$\begin{aligned}\mu = E(x) &= np \sum_{x=0}^n \frac{(n-1)!}{l!(n-1-l)!} p^{x-1} q^{n-1-l} \\ &= np(p+q)^{n-1}\end{aligned}$$

Y como  $p + q = 1$ , se tiene

$$\boxed{\mu = E(X) = np}$$

Una demostración alternativa de la media usando la esperanza matemática es la siguiente:

Puesto que la variable aleatoria  $X$ , está definida como el número de éxitos obtenidos en los  $n$  ensayos de Bernoulli, entonces

$$X = X_1 + X_2 + X_3 + \dots + X_n$$

donde  $X_i$ ,  $i = 1, 2, \dots, n$  es una variable aleatoria con una distribución de probabilidad de Bernoulli. Es decir,  $X_i$  está definido por, 1, si el resultado del ensayo es un éxito y 0 si el resultado del experimento es un fracaso. Hemos visto que

$$E(X_i) = p, \quad i = 1, 2, \dots, n$$

Por lo tanto

$$\begin{aligned}\mu = E(X) &= E(X_1) + E(X_2) + \dots + E(X_n) \\ &= p + p + \dots + p = np\end{aligned}$$

La varianza, se puede determinar aplicando, la propiedad

$$\begin{aligned}\sigma_X^2 &= E(X^2) - (E(X))^2 \\ E(X^2) &= \sum_{x=0}^n x^2 \binom{n}{x} p^x q^{n-x} \\ &= \sum_{x=0}^n x^2 \binom{n}{x} p^x q^{n-x} - \sum_{x=0}^n n \binom{n}{x} p^x q^{n-x} + \sum_{x=0}^n x \binom{n}{x} p^x q^{n-x} \\ &= \sum_{x=0}^n x(x-1) \binom{n}{x} p^x q^{n-x} + \sum_{x=0}^n x \binom{n}{x} p^x q^{n-x} \\ &= \sum_{x=0}^n x(x-1) \binom{n}{x} p^x q^{n-x} + np\end{aligned}$$

pero

$$\begin{aligned}x(x-1) \binom{n}{x} &= x(x-1) \frac{n!}{x!(n-x)!} = \frac{n!}{(x-2)!(n-x)!} \\ &= n(n-1) \frac{(n-2)!}{(x-2)!(n-x)!} = n(n-1) \binom{n-2}{x-2}\end{aligned}$$

Por lo tanto

$$\begin{aligned}
 \sigma_X^2 &= \sum_{x=2}^n n(n-1) \binom{n-2}{x-2} p^{x-2} q^{n-x} p^2 + np \\
 &= n(n-1)p^2 \sum_{n=2}^n \binom{n-2}{x-2} p^{x-2} q^{n-x} + np \\
 &= n(n-1)p^2 \sum_{k=0}^n \binom{n-2}{k} p^k q^{n-2-k} + np \\
 &= n(n-1)p^2(p+q)^{n-2} + np \\
 &= n(n-1)p^2 + np
 \end{aligned}$$

Luego

$$\begin{aligned}
 \sigma_X^2 = \text{Var}(X) &= n(n-1)p^2 + np - n^2p^2 \\
 &= np^2(n-1-n) + np \\
 &= np(1-p) = npq
 \end{aligned}$$

$$\boxed{\sigma_X^2 = \text{Var}(X) = npq}$$

De donde  $\sigma = \sqrt{npq}$  la desviación estándar de X. Para la varianza también una demostración alternativa para el lector que conoce el capítulo 4 es la siguiente:

Hemos visto que  $\sigma_{X_i}^2 = pq$ . Además sabemos que las variables aleatorias  $X_i$  son independientes. Entonces

$$\begin{aligned}
 \sigma_X^2 = \text{Var}(X) &= \text{Var}(X_1) + \text{Var}(X_2) + \dots + \text{Var}(X_n) \\
 &= pq + pq + \dots + pq = npq
 \end{aligned}$$

### 2.3. Distribución multinomial

Consideremos un experimento  $\varepsilon$  con espacio muestral  $\Omega$  con la siguiente característica:

1. Tiene  $k$  posibles resultados  $E_1, E_2, \dots, E_k$  mutuamente excluyentes y colectivamente exhaustivos, es decir  $E_i \cap E_j = \emptyset$ ,  $i \neq j$ ,  $i, j = 1, 2, \dots, k$ ;  $\bigcup_{i=1}^k E_i = \Omega$ .

2.  $P[E_i] = p_i$ ,  $i = 1, 2, \dots, k$ , tal que  $\sum_{i=1}^k p_i = 1$ . En particular, si  $k = 2$ , el experimento  $\varepsilon$  es un ensayo de Bernoulli.

Consideremos ahora una secuencia de  $n$  ensayos independientes con la característica (1.) y (2.). Es decir cada ensayo tiene  $k$  resultado y  $p_i$ ,  $i = 1, 2, \dots, k$  es constante en cada ensayo. Definimos un avariable aleatoria  $X_i$  como sigue

$X_i(w) =$  número de veces que el evento  $E_i$  ocurre en las  $n$  repeticiones de  $\varepsilon$ .  $R_{X_i} = \{0, 1, 2, \dots, n\}$

La distribución de probabilidad conjunta de las variables aleatorias  $X_1, X_2, \dots, X_k$  se llama *distribución multinomial*, se define por

$$p(x_1, x_2, \dots, x_k) = P[X_1 = x_1, \dots, X_k = x_k] = \frac{n!}{x_1!x_2! \dots x_k!} p_1^{x_1} p_2^{x_2} \dots p_k^{x_k}$$

donde  $\sum_{i=1}^k x_i = n$

Observe que  $X_1, X_2, \dots, X_k$  no son variables aleatorias independientes, puesto que  $\sum_{i=1}^k x_i = n$ . Es decir, conocido los valores de  $k-1$  variables aleatorias cualesquiera, se conoce la que falta.

La media y la varianza se las variables aleatorias  $X_i$  son

$$E(X_i) = np_i; \quad \text{Var}(X_i) = np_i(1-p_i), \quad i = 1, 2, \dots, k$$

## 2.4. Distribución de Poisson

### 2.4.1. Distribución de Poisson como aproximación de la binomial

Mostraremos ahora la distribución de Poisson como un límite de la distribución binomial, con  $\lambda = np$ . Donde  $p$  debe ser suficientemente pequeño y  $n$  grande, de tal manera que  $np$  permanece casi constante. La distribución binomial para  $x$  éxitos en  $n$  ensayos de Bernoulli es

$$P[X = x|B; n, p] = \binom{n}{x} p^x q^{n-x} \quad x = 0, 1, 2, \dots, n$$

Hacemos  $\lambda = np$ , luego  $p = \frac{\lambda}{n}$  y  $q = 1 - p = 1 - \frac{\lambda}{n}$

Reemplazando en la fórmula se tiene  $P[X = n] = \frac{n!}{x!(n-x)!}$