

Tema 65

Distribuciones de probabilidad discretas. Características y tratamiento. La distribución binomial y la de Poisson. Aplicaciones

65.1 Conceptos básicos en Teoría de la Probabilidad

Sea Ω un conjunto arbitrario y notemos por $\mathcal{P}(\Omega)$ al conjunto de sus partes.

Definición 1 \mathcal{C} es una clase de conjuntos de Ω sii $\mathcal{C} \subset \mathcal{P}(\Omega)$.

Definición 2 Se dice que una clase $\mathcal{C} \subset \mathcal{P}(\Omega)$ es una σ -álgebra¹ sii verifica las siguientes propiedades:

- (1) $\emptyset \in \mathcal{C}$
- (2) $\{A_n\}_{n=1}^{\infty} \subset \mathcal{C} \Rightarrow \bigcap_{n=1}^{\infty} A_n \in \mathcal{C}$
- (3) $A \in \mathcal{C} \Rightarrow A^c \in \mathcal{C}$

Algunas **propiedades** de las σ -álgebras que se deducen de la definición son:

- (a) $\Omega \in \mathcal{C}$

¹También es usual llamar σ -campos a las σ -álgebras.

$$(b) \{A_n\}_{n=1}^{\infty} \subset \mathcal{C} \Rightarrow \bigcup_{n=1}^{\infty} A_n \in \mathcal{C}$$

Definición 3 Una σ -álgebra minimal sobre la clase \mathcal{H} (o σ -álgebra generada por \mathcal{H}) es la mínima clase con estructura de σ -álgebra que contiene a la clase \mathcal{H} , y la notaremos por $\sigma(\mathcal{H})$.

Consideremos \mathbb{R} como conjunto base y sea $\mathcal{Y} = \{I \subset \mathbb{R} : I \text{ es un intervalo}\}$ una clase de conjuntos de \mathbb{R} . Notaremos $\mathcal{B} = \sigma(\mathcal{Y})$ y la llamaremos σ -álgebra de Borel de \mathbb{R} (la demostración de que es una σ -álgebra se deja como ejercicio).

Definición 4 El par $(\mathbb{R}, \mathcal{B})$ se denomina espacio de Borel unidimensional y cada $B \in \mathcal{B}$ se dice que es un conjunto de Borel o boreliano.

Algunos **ejemplos** de conjuntos de Borel son:

- (1) Cualquier intervalo de \mathbb{R} es un conjunto de Borel
- (2) Los números reales son conjuntos de Borel
- (3) Los conjuntos abiertos, los cerrados, los finitos y los numerables son conjuntos de Borel.

¡¡OJO!! Existen subconjuntos de \mathbb{R} que no son conjuntos Borel.

Definición 5 Sea Ω un conjunto arbitrario y $\mathcal{C} \subset \mathcal{P}(\Omega)$ una clase de conjuntos. Una función de conjunto es una función numérica $\varphi : \mathcal{C} \rightarrow \widehat{\mathbb{R}}$, donde $\widehat{\mathbb{R}} = \mathbb{R} \cup \{\pm\infty\}$ es la compactificación de \mathbb{R} por dos puntos.

Definición 6 Al par (Ω, \mathcal{A}) formado por un conjunto arbitrario Ω y una σ -álgebra \mathcal{A} sobre Ω se le denomina espacio medible. Además, si $A \subset \Omega$ es tal que $A \in \mathcal{A}$ se dice que A es un conjunto medible.

Definición 7 Sea (Ω, \mathcal{A}) un espacio medible. Una función de probabilidad o medida de probabilidad sobre (Ω, \mathcal{A}) es una función de conjunto $P : \mathcal{A} \rightarrow \mathbb{R}$ que verifica:

$$\begin{aligned} (i) \quad & P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) \quad \forall \{A_n\} \subset \mathcal{A} \text{ disjuntos} \\ (ii) \quad & P(A) \geq 0 \quad \forall A \in \mathcal{A} \\ (iii) \quad & P(\Omega) = 1 \end{aligned}$$

En este caso, la terna (Ω, \mathcal{A}, P) se denomina espacio de probabilidad.

Definición 8 Dados dos espacios medibles $(\Omega_1, \mathcal{A}_1)$ y $(\Omega_2, \mathcal{A}_2)$, diremos que una aplicación $f : \Omega_1 \rightarrow \Omega_2$ es medible sii $\forall A \in \mathcal{A}_2 \quad f^{-1}(A) \in \mathcal{A}_1$.

Definición 9 Una función medible es una aplicación medible $f : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B})$.

Definición 10 Una variable aleatoria es una función medible definida sobre un espacio de probabilidad, es decir,


$$X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}) \text{ es una variable aleatoria sii } X^{-1}(B) \in \mathcal{A} \quad \forall B \in \mathcal{B} \Leftrightarrow \Leftrightarrow \forall x \in \mathbb{R} \quad X^{-1}([-\infty, x]) \in \mathcal{A}$$

Así, una variable aleatoria es una función medible con valores reales que está definida sobre el espacio muestral asociado a un experimento aleatorio.

La clase de las variables aleatorias es cerrada para todas las operaciones usuales del Análisis.

Sea $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B})$ una variable aleatoria. Entonces, la medida de probabilidad P induce otra medida de probabilidad en el espacio medible $(\mathbb{R}, \mathcal{B})$, que notaremos P_X y que se denomina distribución de probabilidad de X . Además, está definida por:

$$P_X : \mathcal{B} \rightarrow \mathbb{R} \\ P_X(B) = P\{X^{-1}(B)\}$$



Sea $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ una variable aleatoria arbitraria. Entonces, asociada a esta variable aleatoria tenemos definida la siguiente función:

$$F_X : \mathbb{R} \rightarrow \mathbb{R} \\ F_X(x) = P_X\{[-\infty, x]\} = P\{X^{-1}([-\infty, x])\} \equiv P\{X \leq x\}$$

que llamaremos función de distribución de X .

Vamos a justificar esta definición:

Proposición 11 (1) F_X es no decreciente

(2) F_X es continua a la derecha

(3) $F_X(+\infty) = 1$ y $F_X(-\infty) = 0$

65.2 Variables aleatorias discretas

Sea $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ una variable aleatoria arbitraria.

Definición 12 Diremos que X es discreta (v.a.d.) si sólo toma valores en un conjunto numerable E .

Definición 13 Sea X una v.a.d. y F su función de distribución. Asociada a la v.a. X definimos la función masa de probabilidad (FMP) por:

$$\begin{aligned} p : E &\rightarrow \mathbb{R} \\ x &\longrightarrow P(X = x) \end{aligned}$$

En general,

$$\forall B \in \mathcal{A} \quad P(X \in B) = P(X \in B \cap E) = \sum_{x \in B \cap E} P(X = x)$$

Sea $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ una variable aleatoria discreta.

Definición 14 Diremos que existe la esperanza de X sii la serie $\sum_{x \in E} xP(X = x)$ es absolutamente convergente. En cuyo caso, definimos la esperanza de X por:

$$EX = \sum_{x \in E} xP(X = x)$$

Teorema 15 (Esperanza de una función de una variable aleatoria): Sea $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ una variable aleatoria discreta e $Y = g(X)$ otra v.a.d. obtenida a partir de X mediante una transformación medible. Entonces:

- (1) $\exists EY \Leftrightarrow \sum_{x \in E} |g(x)| P(X = x) < +\infty$
- (2) Si $\exists EY$ entonces $EY = \sum_{x \in E} g(x) P(X = x)$

Corolario 16 $\exists EX \Leftrightarrow \exists E|X|$

Veamos algunas propiedades de la esperanza:

Proposición 17 (1) La esperanza de una cte es ella misma.

(2) Si $\exists EX \Rightarrow \exists E[aX + b] = aEX + b$

(3) Sea X una variable aleatoria y $h_1(X), \dots, h_n(X)$ funciones de $X : \forall j = 1, \dots, n \quad \exists Eh_j(X)$. Entonces:

$$\exists E \left[\sum_{j=1}^n h_j(X) \right] = \sum_{j=1}^n Eh_j(X)$$

(4) Si $h(X), g(X)$ son funciones de una variable aleatoria X tales que $h(X) \leq g(X)$ y además $\exists Eh(X), Eg(X)$, entonces

$$Eh(X) \leq Eg(X)$$

Definición 18 Sea $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ una variable aleatoria discreta y consideremos $\forall n \in \mathbb{N}$ la variable aleatoria X^n . Si $\exists EX^n$, dicha esperanza se denomina momento no centrado de orden n de X .

$$EX^n = \sum_{x \in E} x^n P(X = x)$$

Sea $c \in \mathbb{R}$ y consideremos la variable aleatoria $(X - c)^n$. Si $\exists E[(X - c)^n]$, dicha esperanza se denomina momento centrado en c de orden n de X .

$$E[(X - c)^n] = \sum_{x \in E} (x - c)^n P(X = x)$$

Proposición 19 Notaremos $\alpha_k = EX^k$ y $\mu_k = E[(X - c)^k]$. Entonces:

$$\mu_k = \sum_{j=0}^k (-1)^{k-j} \binom{k}{j} \alpha_1^{k-1} \alpha_j$$

$$\alpha_k = \sum_{j=0}^k \binom{k}{j} \alpha_1^{k-1} \mu_j$$

Definición 20 El momento central de orden 2 respecto de la esperanza se llama varianza de X .

$$\text{Var}(X) = E[(X - EX)^2]$$

La raíz cuadrada positiva de la varianza se denomina desviación típica de X .

$$\sigma_X = +\sqrt{\text{Var}(X)}$$

Corolario 21 (Teorema de König): $\text{Var}(X) = EX^2 - (EX)^2$

Definición 22 Sea $k \in \mathbb{R}^+$ y consideremos la variable aleatoria $|X|^k$. Si $\exists E[|X|^k]$ dicha esperanza se denomina momento absoluto de orden k de X .

Los momentos de una distribución, tanto respecto al origen como respecto a la meda, pueden determinarse utilizando la función generatriz de momentos que pasamos a definir.

Definición 23 Sea X una variable aleatoria discreta y $t \in \mathbb{R}$. Si $\exists E[e^{Xt}] \forall t \in]-\varepsilon, \varepsilon[$, decimos que existe la función generatriz de momentos (FGM) de X . Dicha función se nota por:

$$M_X :]-\varepsilon, \varepsilon[\rightarrow \mathbb{R}$$

$$M_X(t) = E[e^{Xt}] = \sum_{x \in E} e^{xt} P(X = x)$$

Algunas **propiedades** de la FGM son:

Proposición 24 (i) La FGM de una variable aleatoria, si existe, es única y determina de forma única a la distribución.

(ii) Si $\exists M_X(t) \quad \forall t \in]-\varepsilon, \varepsilon[$, entonces:

$$(1) \exists EX^n \quad \forall n \in \mathbb{N}$$

$$(2) M_X(t) = \sum_{n=0}^{+\infty} \frac{t^n EX^n}{n!} \quad \forall t \in]-\varepsilon, \varepsilon[$$

$$(3) M_X \text{ es diferenciable y } \frac{d^k}{dt^k} M_X(t) |_{t=0} = EX^k$$

Corolario 25 $M_X \in C^\infty]-\varepsilon, \varepsilon[$ y de hecho M_X es analítica en $]-\varepsilon, \varepsilon[$.

Sea (Ω, \mathcal{A}, P) un espacio de probabilidad y $X : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}, P_X)$ una variable aleatoria discreta con función de distribución F_X .

Definición 26 Se llama función característica de X a la transformada de Fourier-Stieltjes de F_X , es decir,

$$\varphi(t) = \sum_{x \in E} e^{ixt} P(X = x) = E[e^{itX}]$$

Veamos algunas **propiedades** de la función característica:

Proposición 27 (1) $\exists \varphi(t) \quad \forall X$ variable aleatoria y determina de forma única a la distribución de probabilidad.

$$(2) \varphi(0) = 1$$

$$(3) |\varphi(t)| \leq 1$$

(4) Si $\varphi_X(t)$ es la función característica de X , entonces la función característica de la variable aleatoria $Y = aX + b$ es

$$\varphi_Y(t) = e^{ita} \varphi_X(bt)$$

$$(5) \overline{\varphi(t)} = \varphi(-t)$$

(6) φ es real $\Leftrightarrow X$ es simétrica respecto del origen

(7) Si $\exists \alpha_n \quad \forall n \in \mathbb{N}$ entonces

$$(i) \exists \varphi^{(n)}(0) = i^n \alpha_n$$

$$(ii) \exists \varphi^{(n)}(t) = i^n \sum_{x \in E} e^{itx} x^n P(X = x)$$

(8) Si $\exists \varphi^{(2n)}(t)$ entonces

$$\exists \alpha_{2n} = \frac{\varphi^{(2n)}(0)}{i^{2n}}$$

(9) Si $\exists \varphi^{(2n-2)}(t)$ entonces

$$\exists \alpha_{2n-2} = \frac{\varphi^{(2n-2)}(0)}{i^{2n-2}}$$

65.3 Distribución binomial

Fue introducida por Bernoulli en 1713 y es una de las distribuciones discretas más útiles. Su área de aplicación incluye:

- (1) Inspección de calidad
- (2) Control de defectos
- (3) Calidad del servicio telefónico
- (4) Ventas (marketing)
- (5) Mercalotecnia
- (6) Medicina
- (7) Investigación de opiniones
- (8) Otras,...

Supongamos un experimento en el que el resultado es la ocurrencia o no ocurrencia de un evento. Sin pérdida de generalidad, llámese éxito a la ocurrencia del evento y fracaso a la no ocurrencia. La probabilidad de éxito es p y permanece cte en cada ensayo y la de fracaso $q = 1 - p$.

Supongamos además que el experimento se realiza n - veces y que cada una de las realizaciones es independiente de las demás.

Sea X la variable aleatoria que representa el número de éxitos obtenidos en las n - realizaciones del experimento.

Definición 28 *En las condiciones anteriores, se dice que X sigue una distribución binomial de parámetros (n, p) , $X \rightsquigarrow B(n, p)$, con FMP:*

$$P(X = k) = \begin{cases} \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} & k = 0, \dots, n \\ 0 & \text{fuera} \end{cases}$$

Veamos que es una auténtica FMP:

$$P(X = k) \geq 0$$

$$\begin{aligned} \sum_{k=0}^n P(X = k) &= \sum_{k=0}^n \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} = \\ &= [(1-p) + p]^n = 1^n = 1 \end{aligned}$$

Esta distribución permite conocer, cuando se realizan n pruebas repetidas con probabilidad constante, la probabilidad de que se produzcan k éxitos al realizar las n pruebas.

Función de distribución

$$F(x) = P(X \leq x) = \sum_{k \leq x} P(X = k)$$

Esperanza

$$\begin{aligned}
 EX &= \sum_{k=0}^n kP(X = k) = \sum_{k=0}^n k \binom{n}{k} p^k (1-p)^{n-k} = \sum_{k=0}^n k \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = \\
 &= \sum_{k=1}^n \frac{n!}{(k-1)!(n-k)!} p^k (1-p)^{n-k} = \sum_{k=1}^n np \frac{(n-1)!}{(k-1)!(n-k)!} p^{k-1} (1-p)^{n-k} = \\
 &= np \sum_{k=1}^n \binom{n-1}{k-1} p^{k-1} (1-p)^{(n-1)-(k-1)} \stackrel{(1)}{=} np
 \end{aligned}$$

$$EX = np$$

donde en (1) hemos tenido en cuenta que:

$$\sum_{k=1}^n \binom{n-1}{k-1} p^{k-1} (1-p)^{(n-1)-(k-1)} = [(1-p) + p]^{n-1} = 1$$

Varianza

$$\begin{aligned}
 Var(X) &= E[(X - EX)^2] = E[(X - np)^2] = \sum_{k=0}^n (k - np)^2 \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = \\
 &= \sum_{k=0}^n (k^2 - 2knp + n^2p^2) \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = \underbrace{\sum_{k=0}^n k^2 \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}}_{=A} - \\
 &\quad \underbrace{2 \sum_{k=0}^n knp \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}}_{=B} + \underbrace{\sum_{k=0}^n n^2p^2 \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}}_{=C}
 \end{aligned}$$

$$\begin{aligned}
 A &= \sum_{k=1}^n k \frac{n!}{(k-1)!(n-k)!} p^k (1-p)^{n-k} = np \sum_{k=1}^n k \frac{(n-1)!}{(k-1)!(n-k)!} p^{k-1} (1-p)^{n-k} = \\
 &= \left\{ \begin{array}{l} \text{Cambio} \\ k-1 = t \end{array} \right\} = np \sum_{t=0}^{n-1} (t+1) \frac{(n-1)!}{t!(n-1-t)!} p^t (1-p)^{n-t-1} =
 \end{aligned}$$

$$= np \left[\underbrace{\sum_{t=0}^{n-1} t \frac{(n-1)!}{t!(n-1-t)!} p^t (1-p)^{n-t-1}}_{\text{esperanza para } x=t \text{ y } n-1 \text{ elementos}} + \underbrace{\sum_{t=0}^{n-1} \frac{(n-1)!}{t!(n-1-t)!} p^t (1-p)^{n-t-1}}_{=[(1-p)+p]^{n-1}=1} \right] =$$

$$= np[(n-1)p + 1] = n^2p^2 - np^2 + np$$

$$B = -2np \sum_{k=0}^n k \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} - 2npEX = -2nnp = -2n^2p^2$$

$$C = n^2p^2 \sum_{k=0}^n \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = n^2p^2 [(1-p) + p]^n = n^2p^2$$

$$\begin{aligned} \text{Var}(X) &= A + B + C = n^2p^2 - np^2 + np - 2n^2p^2 + n^2p^2 = \\ &= np[1 - (1-p)] = npq \\ \text{Var}(X) &= npq \end{aligned}$$

Momentos respecto del origen

$$E[X^j] = \sum_{k=0}^n k^j \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = \sum_{k=0}^n k^j \binom{n}{k} p^k (1-p)^{n-k}$$

Momentos centrales

$$E[(X - EX)^j] = E[(X - np)^j] = \sum_{k=0}^n (k - np)^j \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}$$

Función generatriz de momentos

$$\begin{aligned} M(t) &= E[e^{tX}] = \sum_{k=0}^n e^{tk} \binom{n}{k} p^k (1-p)^{n-k} = \\ &= \sum_{k=0}^n \binom{n}{k} (e^t p)^k (1-p)^{n-k} = [e^t p + (1-p)]^n \\ M(t) &= [e^t p + q]^n \end{aligned}$$

Calculamos la varianza usando el teorema de König: $\text{Var}(X) = EX^2 - (EX)^2$

$$\frac{dM(t)}{dt} = n(e^t p + 1 - p)^{n-1} p e^t$$

$$\frac{d^2 M(t)}{dt^2} = n(e^t p + 1 - p)^{n-1} p e^t + n(n-1)(e^t p + 1 - p)^{n-2} p e^t p e^t$$

$$EX^2 = \frac{d^2 M(t)}{dt^2} \Big|_{t=0} = np[(n-1)p + 1]$$

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

Función característica

$$\varphi(t) = (e^{it}p + q)^n$$

Reproductividad²

Teorema 29 (Reproductividad en n de $B(n, p)$): Sean $X_k \rightsquigarrow B(n_k, p)$, $k = 1, \dots, m$, y supongamos que son independientes. Entonces:

$$\sum_{k=1}^m X_k \rightsquigarrow B\left(\sum_{k=1}^m n_k, p\right)$$

Demostración:

Sea $S := \sum_{k=1}^m X_k$. Entonces, la FC de S es:

$$\varphi_S(t) = \prod_{k=1}^m \varphi_{X_k}(t) = \prod_{k=1}^m (e^{it}p + q)^{n_k} = (e^{it}p + q)^{\sum_{k=1}^m n_k}$$

luego $S \rightsquigarrow B\left(\sum_{k=1}^m n_k, p\right)$. C.Q.D. \square

Valores de la variable aleatoria binomial a los que corresponde probabilidad o probabilidades máximas

Se tiene

$$\frac{P(X = x)}{P(X = x - 1)} = \frac{\binom{n}{x} p^x (1-p)^{n-x}}{\binom{n}{x-1} p^{x-1} (1-p)^{n-x+1}} = \frac{n-x+1}{x} \frac{p}{q} = 1 + \frac{(n+1)p - x}{xq}$$

Así pues, si:

- $x < (n+1)p$ las probabilidades crecen
- $x = (n+1)p$ las probabilidades permanecen estacionarias
- $x > (n+1)p$ las probabilidades decrecen

Si llamamos m a la parte entera de $(n+1)p$, el máximo se alcanza en $x = m$, llamado moda o también número más probable de éxitos.


En el caso de que $(n+1)p$ sea entero, entonces el máximo también se alcanza en $x = m - 1$.

Tenemos pues el siguiente resultado:

A medida que x va de 0 a n , los valores de la función de masa de la variable aleatoria $X \equiv B(n, p)$ crecen al principio monótonamente y después decrecen monótonamente, alcanzando su mayor valor cuando $x = m$.

²Sea \mathcal{H} una familia de variables aleatorias. Se dice que \mathcal{H} es reproductiva sii $\forall X_1, X_2 \in \mathcal{H}$ independientes, $X_1 + X_2 \in \mathcal{H}$.

Tenemos pues un esquema de la forma:



Por último, hacer notar que la distribución es simétrica si $p = q$; si $p < q$, entonces es asimétrica a la derecha, y si $p > q$, es asimétrica a la izquierda.

65.4 Distribución de Poisson

La variable aleatoria de POISSON fué introducida en 1837 y es la distribución discreta que representa el número de sucesos independientes que ocurren a una velocidad cte en tiempo o en el espacio.

Ejemplos de situaciones que se modelizan mediante la variable de Poisson son:

- (1) Llegadas a un sistema de espera (número de personas que llegan a una tienda en un tiempo determinado).
- (2) Número de bacterias en un cultivo.
- (3) Número de defectos en piezas similares para un material.

Definición 30 Sea X la variable aleatoria que representa el número de sucesos aleatorios independientes que ocurren a una velocidad cte en el tiempo o en el espacio. Se dice que X tiene una distribución de Poisson de parámetro $\lambda > 0$ si su FMP es:

$$P(X = x) = \begin{cases} \frac{e^{-\lambda} \lambda^x}{x!} & x = 0, 1, 2, \dots \\ 0 & \text{fuera} \end{cases}$$


Veamos que es una auténtica FMP:

$$P(X = x) \geq 0$$

$$\sum_{x=0}^{\infty} P(X = x) = \sum_{x=0}^{\infty} \frac{e^{-\lambda} \lambda^x}{x!} = e^{-\lambda} \sum_{x=0}^{\infty} \frac{\lambda^x}{x!} = e^{-\lambda} e^{\lambda} = 1$$

El parámetro λ de la distribución de Poisson representa (como veremos más adelante) el número promedio de ocurrencias de un suceso por unidad de tiempo.

Algunas **gráficas** de la distribución de Poisson son:



Función de distribución

$$F(x) = P(X \leq x) = \sum_{k \leq x} \frac{e^{-\lambda} \lambda^k}{k!}$$

Esperanza

$$\begin{aligned} EX &= \sum_{x=0}^{\infty} xP(X=x) = \sum_{x=0}^{\infty} \frac{x e^{-\lambda} \lambda^x}{x!} = \sum_{x=0}^{\infty} \frac{e^{-\lambda} \lambda^x}{(x-1)!} = \lambda \sum_{x=1}^{\infty} \frac{e^{-\lambda} \lambda^{x-1}}{(x-1)!} = \\ &= \left\{ \begin{array}{l} \text{Cambio} \\ x-1 = m \end{array} \right\} = \lambda \sum_{m=0}^{\infty} \frac{e^{-\lambda} \lambda^m}{m!} = \lambda \end{aligned}$$

$$EX = \lambda$$

Varianza

$$\begin{aligned} Var(X) &= E[(X - EX)^2] = E[(X - \lambda)^2] = \sum_{x=0}^{\infty} (x - \lambda)^2 \frac{e^{-\lambda} \lambda^x}{x!} = \\ &= \underbrace{\sum_{x=0}^{\infty} x^2 \frac{e^{-\lambda} \lambda^x}{x!}}_{=A} - 2\lambda \underbrace{\sum_{x=0}^{\infty} x \frac{e^{-\lambda} \lambda^x}{x!}}_{=B} + \lambda^2 \underbrace{\sum_{x=0}^{\infty} \frac{e^{-\lambda} \lambda^x}{x!}}_{=C} = \end{aligned}$$

$$A = \sum_{x=0}^{\infty} x^2 \frac{e^{-\lambda} \lambda^x}{x!} = \lambda \sum_{x=1}^{\infty} x \frac{e^{-\lambda} \lambda^{x-1}}{(x-1)!} = \left\{ \begin{array}{c} \text{Cambio} \\ x-1=t \end{array} \right\} = \lambda \sum_{t=0}^{\infty} (t+1) \frac{e^{-\lambda} \lambda^t}{t!} =$$

$$= \lambda \underbrace{\sum_{t=0}^{\infty} t \frac{e^{-\lambda} \lambda^t}{t!}}_{=EX=\lambda} + \lambda \sum_{t=0}^{\infty} \frac{e^{-\lambda} \lambda^t}{t!} = \lambda \lambda + \lambda = \lambda(\lambda + 1)$$

$$B = -2\lambda \sum_{x=0}^{\infty} x \frac{e^{-\lambda} \lambda^x}{x!} = -2\lambda \lambda = -2\lambda^2$$

$$C = \lambda^2 \sum_{x=0}^{\infty} \frac{e^{-\lambda} \lambda^x}{x!} = \lambda^2$$

$$Var(X) = A + B + C = \lambda(\lambda + 1) - 2\lambda^2 + \lambda^2 = \lambda$$

$$Var(X) = \lambda$$

Vamos a calcular la varianza de otra forma:

$$EX^2 = \sum_{x=0}^{\infty} x^2 P(X=x) = \sum_{x=0}^{\infty} x^2 \frac{e^{-\lambda} \lambda^x}{x!} = \{x^2 = x(x-1) + x\} =$$

$$= \underbrace{\sum_{x=0}^{\infty} \frac{x(x-1) e^{-\lambda} \lambda^x}{x!}}_{=A} + \underbrace{\sum_{x=0}^{\infty} x \frac{e^{-\lambda} \lambda^x}{x!}}_{=EX=\lambda}$$

$$A = \sum_{x=0}^{\infty} \frac{e^{-\lambda} \lambda^{x-2} \lambda^2}{(x-2)!} = \lambda^2 \sum_{x=0}^{\infty} \frac{e^{-\lambda} \lambda^{x-2}}{(x-2)!} = \left\{ \begin{array}{c} \text{Cambio} \\ x-2=w \end{array} \right\} =$$

$$= \lambda^2 \sum_{w=0}^{\infty} \frac{e^{-\lambda} \lambda^w}{w!} = \lambda^2$$

$$EX^2 = \lambda^2 + \lambda$$

$$Var(X) = EX^2 - (EX)^2 = \lambda^2 + \lambda - \lambda^2 = \lambda$$

Obsérvese que la esperanza y la varianza de esta distribución son iguales. Esta es la propiedad que caracteriza a la distribución de POISSON, ya que además son iguales al parámetro.

Momentos respecto del origen

$$E[X^j] = \sum_{x=0}^{\infty} x^j \frac{e^{-\lambda} \lambda^x}{x!}$$

Momentos centrales

$$E[(X - EX)^j] = E[(X - \lambda)^j] = \sum_{x=0}^{\infty} (x - \lambda)^j \frac{e^{-\lambda} \lambda^x}{x!}$$

FGM

$$\begin{aligned} M(t) &= E[e^{tX}] = \sum_{x=0}^{\infty} e^{tx} \frac{e^{-\lambda} \lambda^x}{x!} = \sum_{x=0}^{\infty} \frac{(e^t \lambda)^x e^{-\lambda}}{x!} = e^{-\lambda} \sum_{x=0}^{\infty} \frac{(e^t \lambda)^x}{x!} = \\ &= e^{-\lambda} e^{e^t \lambda} = e^{e^t \lambda - \lambda} = e^{\lambda(e^t - 1)} \\ M(t) &= e^{\lambda(e^t - 1)} \end{aligned}$$

FC

$$\varphi(t) = e^{\lambda(e^{it} - 1)}$$

Reproductividad

Teorema 31 (Reproductividad de $\mathcal{P}(\lambda)$): Sean $X_k \rightsquigarrow \mathcal{P}(\lambda_k)$, $k = 1, 2, \dots, m$, y supongamos que son independientes. Entonces:

$$\sum_{k=1}^m X_k \rightsquigarrow \mathcal{P}\left(\sum_{k=1}^m \lambda_k\right)$$

Demostración:

Sea $S := \sum_{k=1}^m X_k$. Entonces, la FC de S es:

$$\varphi_S(t) = \prod_{k=1}^m \varphi_{X_k}(t) = \prod_{k=1}^m e^{\lambda_k(e^{it} - 1)} = e^{\sum_{k=1}^m \lambda_k(e^{it} - 1)}$$

luego $S \rightsquigarrow \mathcal{P}\left(\sum_{k=1}^m \lambda_k\right)$. C.Q.D. \square

65.5 Un teorema límite

Teorema 32 Sea $X \rightsquigarrow B(n, p)$. Entonces, llamando $\lambda = np$ se tiene:

$$\lim_{\substack{n \rightarrow +\infty \\ p \rightarrow 0}} \binom{n}{x} p^x (1-p)^{n-x} = \frac{e^{-\lambda} \lambda^x}{x!} \quad \forall x \in \mathbb{N} \cup \{0\}$$

Demostración:

$$\begin{aligned} P(X = x) &= \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x} = \frac{n(n-1)(n-2)\dots(n-x+1)}{n^x x!} (np)^x (1-p)^{n-x} = \\ &= \frac{n(n-1)(n-2)\dots(n-x+1)}{n^x} \frac{\lambda^x}{x!} (1-p)^{n-x} = \frac{(n-1)(n-2)\dots(n-x+1)}{n^{x-1}} \frac{\lambda^x}{x!} (1-p)^{n-x} = \\ &= \frac{\left(1 - \frac{1}{n}\right)\left(1 - \frac{2}{n}\right)\dots\left(1 - \frac{x-1}{n}\right)}{(1-p)^x} \frac{\lambda^x}{x!} (1-p)^{n-x} \longrightarrow \frac{e^{-\lambda} \lambda^x}{x!} \end{aligned}$$

ya que

$$(1 - p)^n = \left[\left([1 + (-p)]^{\frac{1}{-p}} \right)^{-p} \right]^n = e^{-pn} = e^{-\lambda} \quad C.Q.D. \square$$

Criterio de aproximación:

La aproximación de las probabilidades binomiales por las de Poisson son buenas cuando $np < 5$ y $p < 0.1$, en cuyo caso

$$X \rightsquigarrow B(n, p) \Rightarrow X \rightsquigarrow P(np)$$

Es por ser esta distribución una buena aproximación de la binomial cuando p es muy pequeño con respecto a n por lo que a veces se le llama distribución de los “sucesos raros”.