

La clase pasada vimos la distribución

$$X \sim \text{Poisson}(\lambda)$$

en donde X cuenta el número de éxitos cuando el número de experimentos $\text{Bernoulli}(p)$ es muy grande

$$\Rightarrow p \rightarrow 0$$

y $\lambda = np$ el número promedio de éxitos permanece constante

Una manera de escribir a la Poisson es tener

$$X \sim \text{Poisson}(rt), \quad \lambda = rt$$

Con esta parametrización X cuenta el número de éxitos en un intervalo de longitud t y r es el número promedio de éxitos en el intervalo unitario. A r suele llamarse la intensidad

$$\Rightarrow rt \text{ es el número promedio de éxitos en el intervalo } (0, t)$$

Para obtener a la distribución exponencial, vamos a definir a la v.a. T como el tiempo de espera hasta antes del primer éxito.

$\Rightarrow X \sim \text{Poisson}(rt)$

cuando el número de éxitos en el intervalo de tiempo $(0, t)$

y T modela el tiempo hasta que ocurre el primer éxito

$$\Rightarrow P(X=0) = P(T > t)$$

$$\{x \mid X=0\} \equiv \{t \mid T > t\}$$

X no ha alcanzado a contar un éxito en el intervalo $(0, t)$

\Leftrightarrow el tiempo t es menor al tiempo necesario para que ocurra el primer éxito

Como $f_X(x) = \frac{(rt)^x e^{-rt}}{x!}, \quad x=0, 1, 2, \dots$

$$\Rightarrow P(T > t) = P(X=0) = f(0) = e^{-rt}$$

$$\Rightarrow 1 - P(T > t) = 1 - e^{-rt}$$

$$\Leftrightarrow P(T \leq t) = 1 - e^{-rt}$$

$$F_T(t) = 1 - e^{-rt}$$

$$\Rightarrow f_T(t) = \frac{d}{dt} F_T(t) = r e^{-rt}, \quad t > 0$$

\Rightarrow Una distribución exponencial $T \sim \text{Exp}(r)$ tiene función de distribución de probabilidad

$$f_T(t) = r e^{-rt}, \quad t > 0$$

γ modela el tiempo antes de que ocurra el primer éxito en un experimento Poisson con tasa o intensidad constante r .

En muchos casos se suele parametrizar a la $T \sim \text{Exp}(r)$

$$f_T(t) = \frac{1}{r} e^{-\frac{1}{r}t}, \quad t > 0$$

¿ $f_T(t)$ es una distribución de probabilidad?

Claramente $f_T(t) \geq 0 \quad \forall t > 0$

$$\int_0^{\infty} f_T(t) dt = \int_0^{\infty} r e^{-rt} dt$$

$$u = -rt \Rightarrow du = -r dt$$

$$t \rightarrow \infty \Rightarrow u \rightarrow -\infty$$

$$t = 0 \Rightarrow u = 0$$

$$= -\int_0^{-\infty} e^v dv = \int_{-\infty}^0 e^v dv = e^0 - e^{-\infty} \\ = 1$$

No vamos a ver más características de la v.a. $\text{Exp}(r)$ pues es un caso particular de la v.a. $\text{Gamma}(k, r)$.
 Si $X \sim \text{Gamma}(k, r)$

$\Rightarrow X$ mide el tiempo de espera hasta el k -ésimo éxito en experimentos $\text{Poisson}(rt)$

$$f_T(t) = \frac{r^k}{\Gamma(k)} t^{k-1} e^{-rt}, \quad t > 0$$

En donde $\Gamma(k) = \int_0^{\infty} t^{k-1} e^{-t} dt$

Esta función tiene las siguientes características

$$\Gamma(k+1) = k \Gamma(k)$$

y si $k \in \mathbb{N}$

$$\Rightarrow \Gamma(k) = (k-1)! \Rightarrow \Gamma(1) = 1$$

$$\Rightarrow \underline{\text{Exp}(s) \equiv \text{Gamma}(1, r)}$$

Es una función de distribución de probabilidad?

$$f(t) \geq 0 \quad \gamma$$

$$\int_0^{\infty} \frac{r^k}{\Gamma(k)} t^{k-1} e^{-rt} dt$$

$$v = rt \Rightarrow dv = r dt$$

$$\frac{1}{\Gamma(k)} \int_0^{\infty} (rt)^{k-1} e^{-rt} r dt$$

$$\frac{1}{\Gamma(k)} \int_0^{\infty} v^{k-1} e^{-v} dv = \frac{\Gamma(k)}{\Gamma(k)} = 1$$

$$X \sim \text{Gamma}(d, \beta)$$

$$f(x) = \frac{\beta^d}{\Gamma(d)} x^{d-1} e^{-\beta x}$$

$$M_X(t) = \mathbb{E}(e^{xt}) = \int_0^{\infty} e^{xt} \frac{\beta^d}{\Gamma(d)} x^{d-1} e^{-\beta x} dx$$

$$= \int_0^{\infty} \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-(\beta-t)x} dx$$

$$= \frac{\beta^\alpha}{(\beta-t)^\alpha} \int_0^{\infty} \frac{(\beta-t)^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-(\beta-t)x} dx$$

$$= \left(\frac{1}{1-t/\beta} \right)^\alpha$$

Si: $X \sim \text{Gamma}(\alpha, \beta)$

$$\Rightarrow M_X(t) = (1 - t/\beta)^{-\alpha}$$

$$\begin{aligned} \frac{d}{dt} M_X(t) &= -\alpha \left(-\frac{1}{\beta}\right) (1 - t/\beta)^{-\alpha-1} \\ &= \frac{\alpha}{\beta} (1 - t/\beta)^{-\alpha-1} \Big|_{t=0} \\ &= \frac{\alpha}{\beta} \end{aligned}$$

$$\mathbb{E}(X) = \alpha/\beta$$

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$$

$$\mathbb{E}(X^2) = \left. \frac{d^2}{dt^2} M_X(t) \right|_{t=0}$$

$$= \frac{d}{d\beta} [-(d+1)] \left[-\frac{1}{\beta} \right] \left(1 - \frac{t}{\beta}\right)^{-d-2}$$

$$= \frac{d(d+1)}{\beta^2} = \frac{d^2}{\beta^2} + \frac{d}{\beta^2}$$

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$$

$$= \frac{d^2}{\beta^2} + \frac{d}{\beta^2} - \left(\frac{d}{\beta}\right)^2$$

Si $X \sim \text{Gamma}(d, \beta)$

$$\mathbb{E}(X) = d/\beta$$

$$\text{Var}(X) = d/\beta^2$$

Coefficiente de asimetría

$$\gamma_3 = \frac{2}{\Gamma d} = \frac{\mathbb{E}((X-\mu)^3)}{\sigma^3}$$

$$\gamma_4 = 3 + 6/d = \frac{\mathbb{E}((X-\mu)^4)}{\sigma^4}$$

Hemos visto que las distribuciones de probabilidad nos ayudan a describir el comportamiento agregado de un cierto fenómeno. Sin embargo, las distribuciones generalmente dependen de parámetros que gobiernan su comportamiento y que no conocemos.

Una manera de estimar estos parámetros es vía el método de momentos. Tenemos $f_X(x) \leftarrow$ la función de distribución de probabilidad y depende del parámetro $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ que no conocemos

⇒ igualar los k momentos muestrales con los k momentos poblacionales

$$\underbrace{\mathbb{E}(X^j)}_{\substack{\text{función de} \\ \theta = (\theta_1, \theta_2, \dots, \theta_k)}} = \frac{1}{n} \sum_{i=1}^n x_i^j, \quad j = 1, 2, \dots, k$$

Por ejemplo: Si pensamos que $x_1, x_2, \dots, x_n \leftarrow n$ observaciones vienen de una $\text{Gamma}(\alpha, \beta)$. Quizá porque tenemos un histograma o porque existe teoría que así lo indique

$$\Rightarrow \text{Como } \theta = (\alpha, \beta) \Rightarrow k=2$$

$$E(X) = \alpha/\beta = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n x_i \quad \underline{1}$$

$$E(X^2) = \frac{\alpha(\alpha+1)}{\beta^2} = \frac{1}{n} \sum_{i=1}^n x_i^2 \quad \underline{2}$$

$$\Rightarrow \hat{\alpha}_n = \beta \bar{X}_n \quad \underline{1}$$

substituyendo en 2

$$\frac{\beta \bar{X}_n (\beta \bar{X}_n + 1)}{\beta^2} = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$$\frac{\cancel{\beta} \bar{X}_n^2}{\cancel{\beta} \beta} + \frac{\beta \bar{X}_n}{\beta^2} = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$$\Leftrightarrow \bar{X}_n^2 + \frac{1}{\beta} \bar{X}_n = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$$\begin{aligned} \hat{\beta}_n &= \frac{\bar{X}_n}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}_n^2} \\ \hat{\alpha}_n &= \hat{\beta}_n \bar{X}_n \end{aligned} \quad \left. \vphantom{\begin{aligned} \hat{\beta}_n &= \frac{\bar{X}_n}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}_n^2} \\ \hat{\alpha}_n &= \hat{\beta}_n \bar{X}_n \end{aligned}} \right\}$$