

# Capítulo 3

## Transformaciones y esperanza

### 3.1. Introducción

Por lo general estamos en condiciones de modelar un fenómeno en términos de una variable aleatoria  $X$  cuya función de distribución acumulada es  $F_X(x)$ . La pregunta es si estaremos también en condiciones de estudiar el comportamiento de aquellas variables aleatorias que son transformaciones de  $X$ . En este capítulo se estudian algunas técnicas que permiten conocer el comportamiento probabilístico de  $Y = g(X)$ .

### 3.2. Transformaciones para variables aleatorias

Si  $X$  es una variable aleatoria con función de distribución acumulada  $F_X(x)$  entonces cualquier función de  $X$  es también una variable aleatoria. Si se define  $Y = g(X)$  es posible describir el comportamiento probabilístico de  $Y$  en términos de  $X$ .

Formalmente  $y = g(x)$  define un mapa desde el espacio muestral de  $X$  al espacio muestral de  $Y$ . Es decir:

$$g(x) : \mathcal{X} \longrightarrow \mathcal{Y}$$

Se asocia a  $g$  un mapa inverso, denotado por  $g^{-1}$ , definido por:

$$g^{-1}(A) = \{x \in \mathcal{X} : g(x) \in A\} \tag{3.2.1}$$

Para cualquier conjunto  $A \subset \mathcal{Y}$ :

$$\begin{aligned} \Pr(Y \in A) &= \Pr(g(X) \in A) \\ &= \Pr(\{x \in \mathcal{X} : g(x) \in A\}) \\ &= \Pr(X \in g^{-1}(A)) \end{aligned} \quad (3.2.2)$$

### 3.2.1. Caso discreto

Si  $X$  es una variable aleatoria discreta entonces  $\mathcal{X}$  es numerable. El espacio muestral para  $Y = g(X)$  es:

$$\mathcal{Y} = \{y : y = g(x), x \in \mathcal{X}\}$$

el cual también es un conjunto numerable. Usando la ecuación 3.2.2 la función de probabilidad de  $Y$  es:

$$f_Y(y) = \Pr(Y = y) = \sum_{x \in g^{-1}(y)} f_X(x)$$

**Ejemplo 3.2.1** Sea  $X \sim \mathcal{BI}(n, p)$ . Hallar la función de probabilidad de  $Y = g(X) = n - X$ .

**Ejemplo 3.2.2** Sea  $X$  una variable aleatoria con función de probabilidad:

$$f_X(x) = \frac{1}{2n} \quad x = \pm 1, \pm 2, \dots, \pm n$$

Hallar la función de probabilidad de  $Y = g(X) = X^2$ .

### 3.2.2. Caso continuo

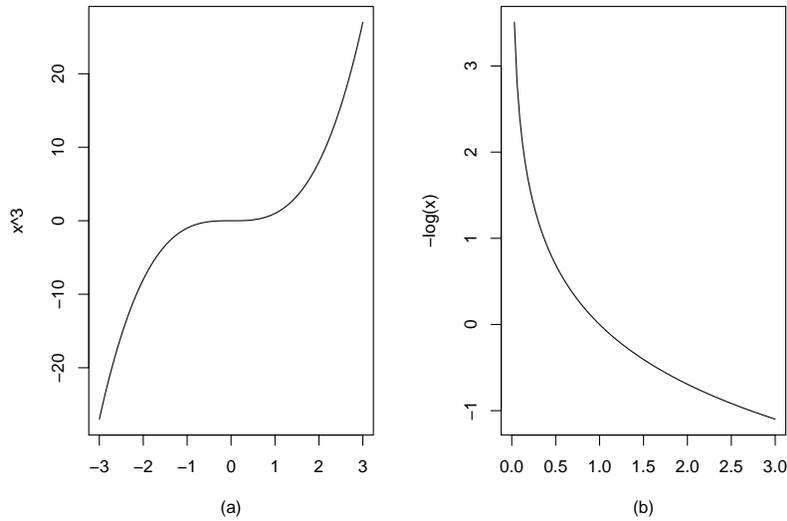
La función de distribución acumulada de  $Y = g(X)$  es:

$$\begin{aligned} F_Y(y) &= \Pr(Y \leq y) \\ &= \Pr(g(X) \leq y) \\ &= \Pr(\{x \in \mathcal{X} : g(x) \leq y\}) \\ &= \int_{\{x \in \mathcal{X} : g(x) \leq y\}} f_X(x) dx \end{aligned} \quad (3.2.3)$$

Es sencillo trabajar con funciones  $g(x)$  que son *monótonas*, es decir aquellas que satisfacen alguna de las siguientes relaciones:

$$u > v \Rightarrow g(u) > g(v) \text{ (creciente)} \quad \text{o} \quad u < v \Rightarrow g(u) > g(v) \text{ (decreciente)}$$

Figura 3.1: Función monótona creciente (a) y decreciente (b)



Si la transformación  $x \rightarrow g(x)$  es monótona entonces es *uno a uno* y *sobreyectiva*. Si  $g$  es creciente:

$$\begin{aligned} \{x \in \mathcal{X} : g(x) \leq y\} &= \{x \in \mathcal{X} : g^{-1}(g(x)) \leq g^{-1}(y)\} \\ &= \{x \in \mathcal{X} : x \leq g^{-1}(y)\} \end{aligned} \quad (3.2.4)$$

y usando 3.2.3, se tiene que:

$$F_Y(y) = \int_{\{x \in \mathcal{X} : x \leq g^{-1}(y)\}} f_X(x) dx = \int_{-\infty}^{g^{-1}(y)} f_X(x) dx = F_X(g^{-1}(y))$$

Si  $g$  es decreciente, entonces:

$$\begin{aligned} \{x \in \mathcal{X} : g(x) \leq y\} &= \{x \in \mathcal{X} : g^{-1}(g(x)) \geq g^{-1}(y)\} \\ &= \{x \in \mathcal{X} : x \geq g^{-1}(y)\} \end{aligned} \quad (3.2.5)$$

se tiene que:

$$F_Y(y) = \int_{g^{-1}(y)}^{\infty} f_X(x) dx = 1 - F_X(g^{-1}(y))$$

Se resumen los resultados anteriores en el siguiente teorema.

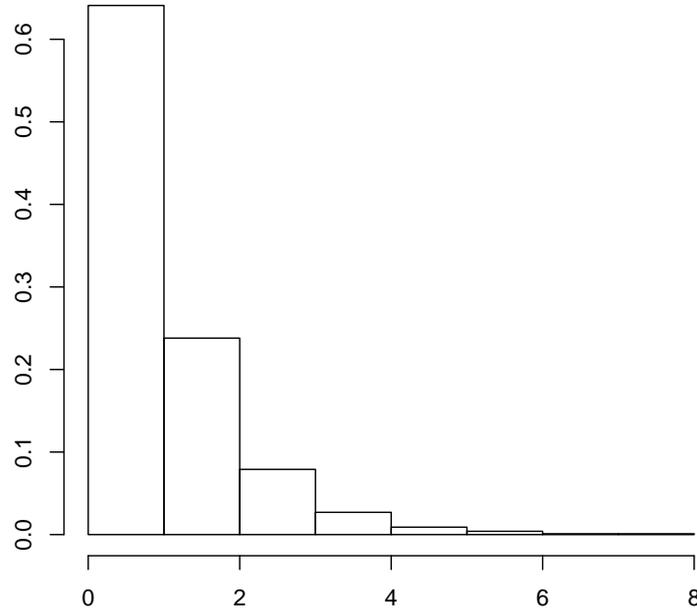
**Teorema 3.2.1** Sea  $X$  una variable aleatoria con función de distribución acumulada  $F_X(x)$ . Se define  $Y = g(X)$  y los espacios muestrales  $\mathcal{X}$  y  $\mathcal{Y}$ .

- a. Si  $g$  es una función creciente sobre  $\mathcal{X}$ , entonces  $F_Y(y) = F_X(g^{-1}(y))$  para  $y \in \mathcal{Y}$ .
- b. Si  $g$  es una función decreciente sobre  $\mathcal{X}$ , entonces  $F_Y(y) = 1 - F_X(g^{-1}(y))$  para  $y \in \mathcal{Y}$ .

**Ejemplo 3.2.3** Suponga que  $X$  tiene distribución uniforme en el intervalo  $(0,1)$ . Demostrar que  $Y = g(X) = -\log X$  tiene distribución exponencial con parámetro  $\beta = 1$ .

En R se pueden generar números aleatorios sobre la distribución uniforme y luego obtener un histograma para los valores transformados según  $g(X)$ .

```
> set.seed(200)
> x <- runif(n=1000, min=0, max=1)
> y <- -log(x)
> hist(y, freq=F, xlab="", ylab="", main="")
```

Figure 3.2: Histograma para  $Y = -\log X$ 

En el ejemplo anterior la función de densidad de  $Y$  se obtiene derivando su función de distribución acumulada. La expresión resultante se presenta en el siguiente teorema.

**Teorema 3.2.2** Sean  $X$  con función de densidad  $f_X(x)$  y  $Y = g(X)$  donde  $g$  es una función monótona. Suponga que  $f_X(x)$  es continua sobre  $\mathcal{X}$  y que  $g^{-1}(y)$  tiene una derivada continua sobre  $\mathcal{Y}$ . Entonces la función de densidad de  $Y$  es:

$$f_Y(y) = \begin{cases} f_X(g^{-1}(y)) \left| \frac{d}{dy} g^{-1}(y) \right| & y \in \mathcal{Y} \\ 0 & \text{de otro modo} \end{cases} \quad (3.2.6)$$

**Demostración:** Usando el teorema 3.2.1 y la regla de la cadena se tiene:

$$f_Y(y) = \frac{d}{dy}F_Y(y) = \begin{cases} f_X(g^{-1}(y)) \frac{d}{dy}g^{-1}(y) & \text{si } g \text{ es creciente} \\ -f_X(g^{-1}(y)) \frac{d}{dy}g^{-1}(y) & \text{si } g \text{ es decreciente} \end{cases}$$

**Ejemplo 3.2.4** Sea  $X \sim \mathcal{W}(\gamma, \beta)$  donde  $\gamma > 0$ . Hallar la distribución de  $Y = g(X) = X^\gamma$ .

En muchas aplicaciones la función  $g$  podría no ser creciente ni decreciente, por consiguiente no podrían aplicarse los resultados anteriores. Sin embargo es común el caso en el que la función  $g$  es monótona sobre ciertos subintervalos, los que permiten obtener una expresión para  $Y = g(X)$ .

**Ejemplo 3.2.5** Suponga que  $X$  es una variable aleatoria continua. La función de distribución acumulada de  $Y = X^2$ , para  $y > 0$ , es:

$$F_Y(y) = \Pr(Y \leq y) = \Pr(X^2 \leq y) = \Pr(-\sqrt{y} \leq X \leq \sqrt{y})$$

Como  $X$  es variable aleatoria continua se tiene:

$$\begin{aligned} F_Y(y) &= \Pr(X \leq \sqrt{y}) - \Pr(X \leq -\sqrt{y}) \\ &= F_X(\sqrt{y}) - F_X(-\sqrt{y}) \end{aligned}$$

La función de densidad de  $Y$  puede obtenerse derivando su función de distribución acumulada:

$$\begin{aligned} f_Y(y) &= \frac{d}{dy}F_Y(y) \\ &= \frac{d}{dy}[F_X(\sqrt{y}) - F_X(-\sqrt{y})] \end{aligned}$$

y usando la regla de la cadena para derivar  $F_X(\sqrt{y})$  y  $F_X(-\sqrt{y})$  se tiene:

$$f_Y(y) = f_X(\sqrt{y}) \frac{1}{2\sqrt{y}} + f_X(-\sqrt{y}) \frac{1}{2\sqrt{y}} \quad (3.2.7)$$

Notar que la función de densidad anterior esta expresada como la suma de dos componentes sobre los intervalos donde  $g(x) = x^2$  es monótona.

**Teorema 3.2.3** Sea  $X$  con función de densidad  $f_X(x)$ ,  $Y = g(X)$  y espacio muestral  $\mathcal{X}$ . Suponga que existe una partición  $A_0, A_1, \dots, A_k$  de  $\mathcal{X}$  tal que  $\Pr(X \in A_0) = 0$  y  $f_X(x)$  es continua sobre cada  $A_i$ . Suponga además que existen funciones  $g_1(x), \dots, g_k(x)$  definidas sobre  $A_1, \dots, A_k$  respectivamente, que satisfacen:

- a.  $g(x) = g_i(x)$  para  $x \in A_i$ ,
- b.  $g_i(x)$  es monótona sobre  $A_i$ ,
- c. El conjunto  $\mathcal{Y} = \{y : y = g_i(x) \text{ para algún } x \in A_i\}$  es el mismo para cada  $i = 1, \dots, k$ .
- d.  $g_i^{-1}(y)$  tiene una derivada continua en  $\mathcal{Y}$ , para cada  $i = 1, \dots, k$ .

Entonces:

$$f_Y(y) = \begin{cases} \sum_{i=1}^k f_X(g_i^{-1}(y)) \left| \frac{d}{dy} g_i^{-1}(y) \right| & y \in \mathcal{Y} \\ 0 & \text{de otro modo} \end{cases}$$

Es importante notar que cada  $g_i(x)$  es una transformación uno a uno desde  $A_i$  hacia  $\mathcal{Y}$ . Además,  $g_i^{-1}(y)$  es una función uno a uno desde  $\mathcal{Y}$  hacia  $A_i$ , tal que, para  $y \in \mathcal{Y}$ ,  $g_i^{-1}(y)$  permite obtener un único  $x = g_i^{-1}(y) \in A_i$  para el cual  $g_i(x) = y$ .

**Ejemplo 3.2.6** Sea  $X \sim \mathcal{N}(0, 1)$ . Demostrar que  $Y = g(X) = X^2$  tiene distribución *chi-cuadrado* con 1 grado de libertad.

En algunos ocasiones la partición  $A_0, A_1, \dots, A_k$  de  $\mathcal{X}$  forma también una partición del conjunto  $\mathcal{Y}$ . En este caso todavía es posible usar 3.2.3.

**Ejemplo 3.2.7** Sea  $X \sim \mathcal{E}(\beta)$ . Hallar la función de densidad de  $Y = g(X) = (X - 2)^2$ .

**Teorema 3.2.4** Sea  $X$  cuya función de distribución acumulada,  $F_X(x)$ , es continua. Si se define la variable aleatoria  $Y = F_X(x)$ , entonces  $Y$  tiene distribución uniforme en el intervalo  $(0, 1)$ .

**Demostración:** Si  $Y = F_X(x)$  entonces  $0 < y < 1$ ,

$$\begin{aligned} \Pr(Y \leq y) &= \Pr(F_X(X) \leq y) \\ &= \Pr(F_X^{-1}(F_X(X)) \leq F_X^{-1}(y)) \\ &= \Pr(X \leq F_X^{-1}(y)) \\ &= F_X(F_X^{-1}(y)) \\ &= y \end{aligned}$$

### 3.3. Valores esperados

**Definición 3.3.1** El *valor esperado* o *media* de una variable aleatoria  $g(X)$ , denotado por  $E[g(X)]$ , es:

$$E[g(X)] = \begin{cases} \sum_{x \in \mathcal{X}} g(x) f_X(x) & \text{si } X \text{ es discreta} \\ \int_{-\infty}^{\infty} g(x) f_X(x) dx & \text{si } X \text{ es continua} \end{cases} \quad (3.3.1)$$

siempre que la integral o suma exista. Si  $E[|g(X)|] = \infty$  se dice que  $E[g(X)]$  no existe.

**Ejemplo 3.3.1** Suponga que  $X \sim \mathcal{E}(\beta)$ , entonces:

$$E[X] = \int_0^{\infty} x \frac{1}{\beta} e^{-x/\beta} dx = \beta$$

**Ejemplo 3.3.2** Si  $X \sim \mathcal{BI}(n, p)$ , entonces:

$$E[X] = \sum_{x=0}^n x \binom{n}{x} p^x (1-p)^{n-x} = \sum_{x=1}^n x \binom{n}{x} p^x (1-p)^{n-x}$$

Usando la identidad  $x \binom{n}{x} = n \binom{n-1}{x-1}$  se tiene:

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

**Ejemplo 3.3.3** Un ejemplo clásico de una variable aleatoria cuyo valor esperado no existe corresponde a la *distribución de Cauchy*.

**Teorema 3.3.1** Sea  $X$  una variable aleatoria y sean  $a$ ,  $b$  y  $c$  constantes. Entonces para funciones cualesquiera  $g_1(x)$  y  $g_2(x)$  cuyos valores esperados existan,

- a.  $E[ag_1(X) + bg_2(X) + c] = aE[g_1(X)] + bE[g_2(X)] + c$ .
- b. Si  $g_1(x) \geq 0$  para todo  $x$ , entonces  $E[g_1(X)] \geq 0$ .
- c. Si  $g_1(x) \geq g_2(x)$  para todo  $x$ , entonces  $E[g_1(X)] \geq E[g_2(X)]$ .
- d. Si  $a \leq g_1(x) \leq b$  para todo  $x$ , entonces  $a \leq E[g_1(X)] \leq b$ .

**Ejemplo 3.3.4** Suponga que se mide la distancia entre una variable aleatoria  $X$  y una constante  $b$  mediante  $(X - b)^2$ . Mientras más cerca esté  $b$  de  $X$  más pequeña será dicha cantidad. El objetivo es determinar el valor de  $b$  que minimize  $E[(X - b)^2]$ .

$$\begin{aligned} E[(X - b)^2] &= E[(X - E[X] + E[X] - b)^2] \\ &= E[((X - E[X]) + (E[X] - b))^2] \\ &= E[(X - E[X])^2] + E[(E[X] - b)^2] \end{aligned}$$

ya que  $E[(X - E[X])(E[X] - b)] = 0$ . Además  $(E[X] - b)$  es una constante. Luego:

$$E[(X - b)^2] = E[(X - E[X])^2] + (E[X] - b)^2$$

Como no se tiene control sobre el primer término del lado derecho y el segundo término puede ser mayor o igual a 0, el menor valor se obtiene cuando  $b = E[X]$ . Entonces:

$$\min_b E[(X - b)^2] = E[(X - E[X])^2]$$

### 3.4. Momentos y función generatriz de momentos

**Definición 3.4.1** Para cada entero  $n$ , el  $n$ -ésimo momento de  $X$ ,  $\mu'_n$ , es:

$$\mu'_n = E[X^n]$$

El  $n$ -ésimo momento central de  $X$ ,  $\mu_n$ , es:

$$\mu_n = E[(X - \mu)^n]$$

donde  $\mu = \mu'_1 = E[X]$ .

**Definición 3.4.2** La *varianza* de una variable aleatoria  $X$  es su segundo momento central,  $\text{Var}(X) = E[(X - \mu)^2]$ . La raíz cuadrada positiva de la varianza es conocida como *desviación estándar*.

**Ejemplo 3.4.1** Si  $X \sim \mathcal{E}(\beta)$ , entonces:

$$\text{Var}(X) = E[(X - \mu)^2] = \int_0^{\infty} (x - \beta)^2 \frac{1}{\beta} e^{-x/\beta} dx = \beta^2$$

**Teorema 3.4.1** Si  $X$  es una variable aleatoria con varianza finita, entonces para constantes cualesquiera  $a$  y  $b$ :

$$\text{Var}(aX + b) = a^2 \text{Var}(X)$$

**Demostración:** Usando la definición de varianza:

$$\begin{aligned} \text{Var}(aX + b) &= E\left[\left((aX + b) - E[(aX + b)]\right)^2\right] \\ &= E\left[\left(aX - aE[X]\right)^2\right] \\ &= a^2 E\left[\left(X - E[X]\right)^2\right] \\ &= a^2 \text{Var}(X) \end{aligned}$$

La siguiente forma de calcular la varianza es bastante útil:

$$\text{Var}(X) = E[X^2] - E^2[X] \tag{3.4.1}$$

**Ejemplo 3.4.2** Si  $X \sim \mathcal{BI}(n, p)$ , entonces:

$$E[X^2] = \sum_{x=0}^n x^2 \binom{n}{x} p^x (1-p)^{n-x}$$

pero:

$$x^2 \binom{n}{x} = x \frac{n!}{(x-1)!(n-x)!} = xn \binom{n-1}{x-1}$$

luego,

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

Finalmente:

$$\text{Var}[X] = n^2 p^2 - np^2 + np - (np)^2 = np(1-p)$$

**Definición 3.4.3** Sea  $X$  una variable aleatoria. La *función generatriz de momentos de  $X$* , denotada por  $M_X(t)$ , es:

$$M_X(t) = E[e^{tX}]$$

sujeto a que el valor esperado exista. Entonces:

$$M_X(t) = \begin{cases} \sum_x e^{tx} f_X(x) & \text{si } X \text{ es discreta} \\ \int_{-\infty}^{\infty} e^{tx} f_X(x) dx & \text{si } X \text{ es continua} \end{cases}$$

**Teorema 3.4.2** Si  $X$  tiene función generatriz de momentos  $M_X(t)$  entonces:

$$E[X] = M_X^{(1)}(0)$$

donde  $M_X^{(n)}(0) = \left. \frac{d^n}{dt^n} M_X(t) \right|_{t=0}$ .

**Prueba:** Asumiendo que es posible intercambiar la derivada con la integral, se tiene:

$$\begin{aligned}\frac{d}{dt}M_X(t) &= \frac{d}{dt} \int_{-\infty}^{\infty} e^{tx} f_X(x) dx \\ &= \int_{-\infty}^{\infty} \left( \frac{d}{dt} e^{tx} \right) f_X(x) dx \\ &= \int_{-\infty}^{\infty} x e^{tx} f_X(x) dx \\ &= \mathbf{E} [X e^{tX}]\end{aligned}$$

luego  $\frac{d}{dt}M_X(t)\Big|_{t=0} = \mathbf{E} [X e^{tX}]\Big|_{t=0} = \mathbf{E} [X]$ . Trabajando de manera análoga, se puede establecer que:

$$\frac{d^n}{dt^n}M_X(t)\Big|_{t=0} = \mathbf{E} [X^n e^{tX}]\Big|_{t=0} = \mathbf{E} [X^n]$$

**Ejemplo 3.4.3** Sea  $X \sim \mathcal{G}(\alpha, \beta)$ . La función generatriz de momentos está dada por:

$$\begin{aligned}M_X(t) &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_0^\infty e^{tx} x^{\alpha-1} e^{-x/\beta} dx \\ &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_0^\infty x^{\alpha-1} e^{-x((1/\beta)-t)} dx \\ &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_0^\infty x^{\alpha-1} e^{-x/(\frac{\beta}{1-\beta t})} dx \\ &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \Gamma(\alpha) \left( \frac{\beta}{1-\beta t} \right)^\alpha \\ &= \left( \frac{1}{1-\beta t} \right)^\alpha\end{aligned}$$

y existe solo si  $t < 1/\beta$ . La media de la distribución gamma es:

$$\mathbf{E} [X] = \frac{d}{dt}M_X(t)\Big|_{t=0} = \frac{\alpha\beta}{(1-\beta t)^{\alpha+1}}\Big|_{t=0} = \alpha\beta$$

Los otros momentos pueden calcularse de forma similar.

**Ejemplo 3.4.4** Si  $X \sim \mathcal{BI}(n, p)$ , entonces:

$$\begin{aligned} M_X(t) &= \sum_{x=0}^n e^{tx} \binom{n}{x} p^x (1-p)^{n-x} \\ &= \sum_{x=0}^n \binom{n}{x} (pe^t)^x (1-p)^{n-x} \\ &= [pe^t + (1-p)]^n \end{aligned}$$

recordando que  $\sum_{x=0}^n \binom{n}{x} u^x v^{n-x} = (u+v)^n$ .

**Teorema 3.4.3** Suponga  $\{X_i, i = 1, 2, \dots\}$  es una secuencia de variables aleatorias cuya función generatriz de momentos es  $M_{X_i}(t)$ . Además:

$$\lim_{i \rightarrow \infty} M_{X_i}(t) = M_X(t)$$

donde  $M_X(t)$  es una función generatriz de momentos. Entonces existe una única función de distribución acumulada  $F_X$  cuyos momentos están definidos por  $M_X(t)$  tal que:

$$\lim_{i \rightarrow \infty} F_{X_i}(x) = F_X(x)$$

**Ejemplo 3.4.5** Una aproximación usada en cursos elementales de estadística permite aproximar las probabilidades binomiales usando la distribución de Poisson. Esta aproximación es válida *cuando  $n$  es grande y  $np$  es pequeño*.

La función de probabilidad de Poisson es:

$$\Pr(Y = y) = \frac{e^{-\lambda} \lambda^y}{y!} \quad y = 0, 1, 2, \dots$$

donde  $\lambda$  es una constante positiva. La aproximación es tal que si  $X \sim \mathcal{BI}(n, p)$  y  $Y \sim \mathcal{P}(\lambda)$  con  $\lambda = np$ , entonces:

$$\Pr(X = x) \approx \Pr(Y = x)$$

Recordar que:

$$M_X(t) = [pe^t + (1-p)]^n$$

es la función generatriz de momentos de la distribución binomial. Para la distribución de Poisson se puede demostrar que su función generatriz de momentos es:

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

Como  $\lambda = np$ , entonces:

$$\begin{aligned} M_X(t) &= [1 + p(e^t - 1)]^n \\ &= \left[1 + \frac{(e^t - 1)\lambda}{n}\right]^n \end{aligned}$$

**Lema 3.4.1** Sean  $a_1, a_2, \dots$  una secuencia de números que convergen hacia  $a$ , es decir  $\lim_{n \rightarrow \infty} a_n = a$ , entonces:

$$\lim_{n \rightarrow \infty} \left(1 + \frac{a_n}{n}\right)^n = e^a$$

**Demostración:** La demostración de este lema puede encontrarse en los textos de cálculo.

Luego, si se toma  $a_n = \lambda(e^t - 1) = a$  entonces:

$$\lim_{n \rightarrow \infty} M_X(t) = e^{\lambda(e^t - 1)} = M_Y(t)$$

es la función generatriz de momentos de la distribución de Poisson.

**Teorema 3.4.4** Sean  $a$  y  $b$  constantes, la función generatriz de momentos de la variable aleatoria  $aX + b$  está dada por:

$$M_{aX+b}(t) = e^{bt} M_X(at)$$

**Prueba:** Por definición:

$$\begin{aligned} M_{aX+b}(t) &= \mathbf{E} [e^{(aX+b)t}] \\ &= \mathbf{E} [e^{aXt} e^{bt}] \\ &= e^{bt} \mathbf{E} [e^{X(at)}] \\ &= e^{bt} M_X(at) \end{aligned}$$