

$\mathbb{X}$  v.a. que nos ayude a modelar un fenómeno aleatorio  
 $f(x)$  función de distribución de probabilidad. Nos muestra  
el patrón agregado que  $\mathbb{X}$  es capaz de describir

$F(x)$  función de distribución acumulada. Nos ayuda a calcular  
 $P_{\mathbb{X}}(\mathbb{X} \in A)$ .

$\mathbb{E}(\mathbb{X})$  indica el valor esperado o promedio que toma  
la v.a.

$$\mathbb{E}(\mathbb{X}) = \begin{cases} \sum_{j=1}^{\infty} x_j f(x_j), & \mathbb{X} \text{ v.o. discreta} \\ \int_{-\infty}^{\infty} x f(x) dx, & \mathbb{X} \text{ v.o. continua.} \end{cases}$$

Además, se tiene que

$$\mathbb{E}(g(\mathbb{X})) = \begin{cases} \sum_{j=1}^{\infty} g(x_j) f(x_j), & \mathbb{X} \text{ v.o. discreta} \\ \int_{-\infty}^{\infty} g(x) f(x) dx, & \mathbb{X} \text{ v.o. continua} \end{cases}$$

se le conoce como el teorema del estadístico inconsciente. (TEI)

En particular se tiene que para funciones lineales

$$g(X) = aX + b$$

$$\mathbb{E}(aX + b) = a\mathbb{E}(X) + b$$

Dem.

$$\begin{aligned} \mathbb{E}(aX + b) &= \int (ax + b) f(x) dx \\ &= a \int x f(x) dx + b \int f(x) dx \\ &= a\mathbb{E}(X) + b \end{aligned}$$

### Momentos de una distribución

Para cualquier entero  $k$ , el  $k$ -ésimo momento de la v.a.  $X$  se define como

$$m_k = \mathbb{E}(X^k)$$

En donde por el T E I sabemos que

$$\mathbb{E}(X^k) = \int x^k f(x) dx$$

Siempre que  $\mathbb{E}(|X|^k) < \infty$  entonces que el  $k$ -ésimo momento de la v.c.  $X$  existe.

El primer y segundo momento sean relevantes

$$m_1 = \mathbb{E}(X) = \mu \quad \text{y} \quad m_2 = \mathbb{E}(X^2)$$

Momentos alrededor de la media =  $\mathbb{E}(X)$

$$\mu_k = \mathbb{E}((X - \mu)^k)$$

también son conocidas como momentos centrales de la v.c.  $X$

Segundo momento central: Varianza

$$\mu_2 = \mathbb{E}((X - \mu)^2) = \text{Var}(X) = \sigma^2$$

nos da información de la desviación promedio entre los valores que toma la v.c.  $X$  y su valor promedio [unidades de la v.c. al cuadrado]

Es fácil demostrar que

$$\begin{aligned} \sigma^2 = \text{Var}(X) &= \mathbb{E}((X - \mu)^2) \\ &= \mathbb{E}(X^2) - \mu^2 \\ &= m_2 - m_1^2 \end{aligned}$$

$$\begin{aligned}
\mathbb{E}((X-\mu)^2) &= \mathbb{E}(X^2 - 2X\mu + \mu^2) \\
&= \int (x^2 - 2x\mu + \mu^2) f(x) dx \\
&= \int x^2 f(x) dx - 2\mu \int x f(x) dx + \mu^2 \int f(x) dx \\
&= \mathbb{E}(X^2) - 2\mu^2 + \mu^2 \\
&= \mathbb{E}(X^2) - \mu^2 \quad \downarrow
\end{aligned}$$

En el caso de la varianza de  $X$  tener que

Para una constante  $b$ ,  $\text{Var}(b) = 0$

$$\begin{aligned}
\text{Var}(b) &= \mathbb{E}(b^2) - \mathbb{E}(b)^2 \\
&= b^2 - b^2 = 0
\end{aligned}$$

Una constante tiene varianza 0, no se desvía con respecto a su valor promedio.

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

$$\text{Var}(aX + b) = \mathbb{E}((aX + b)^2) - \mathbb{E}(aX + b)^2$$

$$\begin{aligned}
&= \mathbb{E}(a^2 X^2 + 2abX + b^2) - (a\mu + b)^2 \\
&= a^2 \mathbb{E}(X^2) + \cancel{2ab\mu} + b^2 - (a^2\mu^2 + \cancel{2ab\mu} + b^2) \\
&= a^2 (\mathbb{E}(X^2) - \mu^2) = a^2 \text{Var}(X) \quad \downarrow
\end{aligned}$$

$$G = \sqrt{G^2} = \sqrt{\text{Var}(X)} \quad \text{es conocida}$$

Como la desviación estándar de  $X$  y de la misma forma que  $G^2$  nos da información acerca de las desviaciones entre los valores se tome  $X$  y su valor promedio. La diferencia es que  $G$  está en las mismas unidades que  $X$  por lo que en general se interpreta de forma más clara y fácil.

Tercer momento central: Asimetría


Al tercer momento central

$$\mu_3 = \mathbb{E}((X - \mu)^3)$$

se le llama asimetría de la v.o. y nos da información acerca de si la v.o. toma con mayor probabilidad valores

a la izquierda de 0 a la derecha de la media. Para cancelar el efecto de la dimensión suele definirse el coeficiente de asimetría

$$\gamma_3 = \frac{\mu_3}{G^3}$$




Cuarto momento central: Curtosis

$$\mu_4 = E((X - \mu)^4)$$

para eliminar el efecto de la potencia

$$\gamma_4 = \frac{\mu_4}{G^4} \leftarrow \text{coeficiente de curtosis}$$

Nos da información de que tan picuda o chata es una distribución.



## Aplicación: interpretación

$\mu$   
= media

nos da información de la localización de la distribución de  $X$ , así como de su valor promedio o esperado. Y es el candidato por el mejor representante de los valores que puede tomar la v.a.

$\sigma^2$  y  $\sigma$   
varianza

nos da información acerca de que tan juntos o dispersos se encuentran los valores que puede tomar  $X$  con respecto a  $\mu$ .

$\mu^3$  y  $\gamma_3$   
asimetría

nos dice si la v.a. toma con mayor probabilidad valores a la izquierda o a la derecha de su valor esperado.

$\mu^4$  y  $\sigma_4$   
curtosis

Nos indica cuanta variante se debe a observaciones extremas (lo cde).

Mayor curtosis = picos más agudos y colas más pesadas  $\Rightarrow$  los valores extremos que tome la v.a. contribuyen más a la variante.

Menor curtosis = picos chatos y colas ligeras  $\Rightarrow$  los valores extremos no contribuyen mucho a la variante y este está determinado principalmente por los valores alrededor de  $\mu$ .

## Función generadora de momentos

La función generadora de momentos de una v.a.  $X$ , se define como

$$M_X(t) = \mathbb{E}(e^{Xt}) = \begin{cases} \sum_{j=1}^{\infty} e^{Xjt} f(x_j), & X \text{ discreta} \\ \int_{-\infty}^{\infty} e^{xt} f(x) dx, & X \text{ continua} \end{cases}$$

Se le llama fgm porque



$$\mathbb{E}(\Sigma^k) = m_k = \left. \frac{d^k}{dt^k} M_{\Sigma}(t) \right|_{t=0}$$

La función generadora de momentos tiene las siguientes propiedades

1. Unicidad. La fgm no existe para todos los v.o.  $\Sigma$ , pero cuando existe determina de manera única la distribución de la v.o.  $\Sigma$

$\Rightarrow$  Si dos v.o.  $\Sigma \in \mathcal{I}$  tienen la misma fgm ( $M_{\Sigma}(t) = M_{\mathcal{I}}(t)$ ) entonces tienen la misma distribución.

2 = Transformaciones lineales.

$$\text{Si } \mathcal{I} = a\Sigma + b$$

$$\Rightarrow M_{\mathcal{I}}(t) = e^{bt} M_{\Sigma}(at)$$

3 = Sumas de v.o. independientes.

$$\text{Si } \Sigma \perp \mathcal{I} \quad \text{y} \quad Z = \Sigma + \mathcal{I}$$

$$\Rightarrow M_Z(t) = M_{\Sigma}(t) M_{\mathcal{I}}(t)$$