

TEMA 65: DISTRIBUCIONES DE PROBABILIDAD DE UNA VARIABLE ALEATORIA DISCRETA. CARACTERÍSTICAS Y TRATAMIENTO. LAS DISTRIBUCIONES BINOMIAL Y DE POISSON. APLICACIONES

TIEMPO: 61 — 62

Esquema

- 1) Introducción
 - 1.1) Caballero de la Mére + Pascal + Fermat
 - 1.2) J. Bernoulli + Moivre
 - 1.3) Gauss
 - 1.4) Laplace + Poisson
- 2 Definiciones
 - 2.1) Definición: variable aleatoria
 - 2.2) Definición: v.a. discreta
- 3) Variables Aleatorias discreta
 - 3.1) Distribución de probabilidad
 - 3.1.1) Definición: distribución de probabilidad
 - 3.2) Función de distribución
 - 3.2.1) Definición: distribución de distribución + propiedades
 - 3.3) Momentos de una variable aleatoria
 - 3.3.1) Definición: media + momentos no centrados
 - 3.3.2) Definición: momentos no centrados + σ^2
 - 3.3.3) Fórmulas
 - 3.4) Función generatriz de momentos
 - 3.4.1) Definición: fgm + función característica
- 4) Distribución Binomial
 - 4.1) Experimento de Bernoulli
 - 4.2) Definición: Binomial + propiedades
 - 4.3) Definición: distribución multinomial
- 5) Distribución de Poisson
 - 5.1) Definición: límite de la Binomial + fórmula + propiedades
- 6) Además
 - 6.1) Otras distribuciones discretas
 - 6.2) Aproximación de una empírica por una teórica

1) Introducción:

▷ En el s. XVII Antoine Gomband, más conocido como el Caballero de la Mére, propone a Pascal el siguiente problema: “al lanzar 24 veces un par de dados, ante la aparición de por lo menos un seis doble en las 24 tiradas, ¿es lo mismo apostar la misma cantidad a favor que en contra?”

▷ En relación a este problema y otros de la misma índole se inicia una relación epistolar entre Pascal y Fermat que se considera el inicio del Cálculo de Probabilidades.

▷ La historia del Cálculo de Probabilidades comienza con Jakob Bernouilli y de Moivre, quien formula y prueba por primera vez el Teorema Central del Límite. La obra póstuma de Bernouilli, quien perteneció a una extensa saga familiar suiza de matemáticos y físicos, “El arte de pronosticar” constituye el primer tratado importante acerca de probabilidades.

▷ Moivre (s. XVII - s. XVIII), matemático francés, formuló la probabilidad de sucesos independientes. Publicó varias obras donde estudiaba la probabilidad compuesta y a principios del s.XVIII aparece en su obra, por primera vez, la campana de Gauss.

▷ Karl Friedrich Gauss (s. XVIII - s. XIX) fue un matemático y físico alemán con contribuciones esenciales en el campo de la física y la astronomía. En lo concerniente a las Matemáticas, abarca un número muy amplio de ramas: desarrolla el Teorema de los Número Primos, una geometría no euclídea por primera vez, el método de los mínimos cuadrados, las leyes básicas de la probabilidad,...

▷ Entre Moivre y Gauss nos encontramos con Pierre Simón, marqués de Laplace. También mencionamos a Simeon Denis Poisson (s. XVIII - s. XIX) quien trabajó sobre los resultados de Laplace y analiza sucesos de probabilidad muy pequeña, lo que le condujo a la distribución que hoy lleva su nombre.

2) Definiciones:

▷ **Definición:** sea (Ω, \mathcal{A}, P) un espacio de probabilidad asociado a un experimento aleatorio. Decimos que $\mathbb{X} : \Omega \mapsto \mathbb{R}$ es una variable aleatoria \iff la imagen inversa de cualquier conjunto Borel es un elemento de \mathcal{A} .

▷ *Nota:* la σ -álgebra de los conjuntos de Borel es la σ -álgebra más pequeña que contiene a todos los abiertos de \mathbb{R} .

▷ **Proposición:** son equivalentes

- a) \mathbb{X} es una variable aleatoria
- b) La imagen inversa de cualquier abierto de \mathbb{R} pertenece a \mathcal{A}
- c) La imagen inversa de cualquier cerrado de \mathbb{R} pertenece a \mathcal{A}
- d) $\mathbb{X}^{-1}(] - \infty, x]) \in \mathcal{A}, \forall x \in \mathbb{R}$

▷ **Definición:** si suponemos que $\mathbb{X} = \mathbb{X}(a)$ toma un conjunto numerable de valores reales $\{x_n\}$ y el conjunto $A_n = \{a \in \Omega / \mathbb{X}(a) = x_n\}$ es tal que $A_n \in \mathcal{A}$, diremos que $\mathbb{X} : (\Omega, \mathcal{A}, P) \mapsto \mathbb{R}$ es una variable aleatoria discreta.

3) Variables Aleatorias Discretas:

▷ Distribución de Probabilidad:

▷ Previamente, veamos cómo a un suceso cualquiera se le puede asignar una variable aleatoria. Sea un suceso aleatorio A , definimos la variable aleatoria indicador de A , χ_A dada por: $\chi_A = \{1$ si se presenta A al realizar el suceso; 0 si no se presenta $A\}$. Por tanto tenemos:

$$P[\chi_A = 1] = P(A), P[\chi_A = 0] = P(\bar{A}) = 1 - P(A)$$

Sea \mathbb{X} una variable aleatoria discreta que toma valores x_n con $n = 1, 2, \dots$. Vamos a asociarle a esta v.a. un conjunto de sucesos: sea el suceso A definido por $\emptyset \neq A_n = \{a \in \Omega \text{ tq } \mathbb{X}(a) = x_n\}$.

1) $A_n \cap A_m = \emptyset$ si $n \neq m$, pues si $a \in A_n \cap A_m \rightarrow \mathbb{X}(a) = x_n = x_m$ lo que es una contradicción. Luego los $\{A_n\}$ son incompatibles.

$$2) \bigcup_{n=1}^{\infty} A_n = \Omega$$

$$3) P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) = P(\Omega) = 1$$

Las condiciones (1) y (2) definen lo que se llama un sistema completo de sucesos y si también se verifica (3) tenemos una distribución de probabilidad (finita o numerable).

▷ **Definición:** una distribución de probabilidad se puede considerar como la sucesión de probabilidades que corresponden a los sucesos de un sistema completo o como la sucesión de probabilidades con que la variable aleatoria toma sus valores. $P_k = P[\mathbb{X} = x_k]$

▷ **Teorema:** si \mathbb{X} es una v.a. discreta definida en $(\Omega, \mathcal{A}, P) \Rightarrow \mathbb{Y} = g(\mathbb{X})$ tal que $g(\mathbb{X})$ es un función real cualquiera, es otra v.a. definida en (Ω, \mathcal{A}, P) .

▷ Función de Distribución:

▷ **Definición:** llamamos función de distribución de una v.a. discreta, y la notamos por $F(x)$, al valor $P[\mathbb{X} \leq x]$, $\forall x \in \mathbb{R}$; $F(x) = P[\mathbb{X} \leq x] = \sum_{x_j \leq x} P[X = x_j]$

▷ Propiedades:

1) $F(x)$ es continua por la derecha $\forall x \in \mathbb{R}$

2) $F(x)$ es creciente y no negativa

3) $\lim_{x \rightarrow -\infty} F(x) = 0$; $\lim_{x \rightarrow +\infty} F(x) = 1$

▷ Nota: a partir de $F(x)$ podemos conocer probabilidades como $P[a < \mathbb{X} \leq b] = F(b) - F(a)$. Además $F(x)$ tiene la ventaja de ser una función real de variable real, cosa que no suele ocurrir con la variable aleatoria \mathbb{X} . Además, si tenemos $F : \mathbb{R} \mapsto \mathbb{R}$ cumpliendo **(1)**, **(2)** y **(3)** $\Rightarrow F$ es la función de distribución de alguna variable aleatoria \mathbb{X} .

▷ Momentos de una v.a. discreta:

▷ Sea \mathbb{X} una v.a. discreta definida sobre (Ω, \mathcal{A}, P) y sean $x_j, j = 1, 2, \dots$ los valores que toma \mathbb{X} con probabilidades respectivas p_j , es decir: $P[\mathbb{X} = x_j] = p_j$

▷ Definición: llamaremos media/esperanza matemática al número $E[\mathbb{X}] = \sum_{j=1}^{\infty} x_j \cdot p_j$ en caso de existir. La esperanza es un operador lineal, esto es: $E[a\mathbb{X} + b\mathbb{Y}] = a \cdot E[\mathbb{X}] + b \cdot E[\mathbb{Y}]$

▷ Definición: sea \mathbb{X} una v.a. discreta definida sobre (Ω, \mathcal{A}, P) y supongamos que existe $E[\mathbb{X}^n]$, $n \in \mathbb{N}$. A dicho valor lo llamaremos momento no centrado de orden "n" de la v.a. \mathbb{X} . Si $\exists E[\mathbb{X}^n] \rightarrow \exists E[\mathbb{X}^k], \forall k \leq n$. Lo notaremos por m_n .

▷ Definición: supongamos que existe $E[\mathbb{X}^n]$, llamamos momento centrado de orden "n" al valor $\mu_n = E[(\mathbb{X} - m_1)^n] = E[(\mathbb{X} - E[\mathbb{X}])^n]$
Si $\exists \mu_n \rightarrow \mu_k, \forall k \leq n$

▷ Proposición: de la linealidad de la esperanza se deducen las siguientes fórmulas:

- $\mu_n = m_n - \binom{n}{1} m_1 \cdot m_{n-1} + \binom{n}{2} m_1^2 \cdot m_{n-2} + \dots + (-1)^n \binom{n}{n} m_1^n$
- $m_n = \mu_n + \binom{n}{1} m_1 \cdot \mu_{n-1} + \binom{n}{2} m_1^2 \cdot \mu_{n-2} + \dots + \binom{n}{n} m_1^n$

▷ Definición: si existe $E[\mathbb{X}^2]$, μ_2 recibe el nombre de varianza de \mathbb{X} y la notamos por σ^2 .

▷ Definición: llamamos desviación típica a: $+\sqrt{\sigma^2} = \sigma$

De las fórmulas obtenemos que: $\mu_2 = \sigma^2 = E[(\mathbb{X} - E[\mathbb{X}])^2] = E[\mathbb{X}^2] - (E[\mathbb{X}])^2$

Proof. $\mu_2 = m_2 - \binom{2}{1} m_1 \cdot m_1 + \binom{2}{2} m_1^2 = m_2 - m_1^2 = E[\mathbb{X}^2] - (E[\mathbb{X}])^2$ □

▷ **Función Generatriz de Momentos:**

▷ Sea \mathbb{X} una v.a. discreta definida sobre (Ω, \mathcal{A}, P) .

▷ **Definición:** la función $M(t) = E[e^{t\mathbb{X}}] = \sum_{k=0}^{\infty} e^{t \cdot x_k}$ se llama función generatriz de momentos de la variable aleatoria \mathbb{X} , en caso de estar definida en un entorno de $t = 0$, $]-\epsilon, \epsilon[$

▷ Se puede demostrar que si existe la f.g.m. entonces es infinitamente derivable en $t = 0$ y, además, se obtiene que $M^{(n)}(0) = E[\mathbb{X}^n] = m_n$, es decir, nos da los momentos no centrales sin más que derivar en cero.

▷ **Definición:** llamamos función característica a: $\varphi_{\mathbb{X}}(t) = E[e^{it\mathbb{X}}] = M(i \cdot t)$

4) Distribución Binomial:

▷ La llamada distribución de Bernoulli considera un experimento con dos únicos resultados (éxito o fracaso) con sus respectivas probabilidades p y $q (= 1 - p)$. Si \mathbb{X} es la v.a. “número de éxitos”, la distribución de probabilidades es:

$$P[\mathbb{X} = 1] = p, P[\mathbb{X} = 0] = q = 1 - p \text{ y } \bar{x} = E[\mathbb{X}] = p, \sigma^2 = p \cdot q$$

▷ Por ejemplo: obtener cara al lanzar una moneda, obtener un 6 en el lanzamiento de un dado,...

Si repetimos el experimento de Bernoulli “ n ” veces tal que sean pruebas independientes lo que obtenemos es la llamada Distribución Binomial.

En relación al experimento aleatorio dado, consideremos el suceso A (éxito) y su complementario \bar{A} (fracaso). Supongamos que $P(A) = p, P(\bar{A}) = 1 - p = q$. Además, la probabilidad se mantiene fija en cada observación y no depende de los resultados anteriores.

▷ **Definición**: definimos la variable binomial \mathbb{X} como el número de éxitos tras “ n ” pruebas.

▷ **Distribución de probabilidad**: $P[\mathbb{X} = k] = \binom{n}{k} p^k \cdot q^{n-k}$

Proof. Veamos que cumple las condiciones para ser distribución de probabilidad:

a) $P[X = k] \geq 0$ por ser $p, q > 0$.

$$b) \sum_{k=0}^n P[X = k] = \binom{n}{0} p^0 \cdot q^n + \dots + \binom{n}{n} p^n \cdot q^0 = (p + q)^n = 1$$

Supongamos que tenemos “ k ” éxitos en “ n ” tiradas. Una manera de obtenerlos es $A \overbrace{\dots}^k A \overbrace{\dots}^{n-k} \bar{A}$ y $P[A \dots A \bar{A} \dots \bar{A}] = p \dots p \cdot q \dots q = p^k \cdot q^{n-k}$. Pero cualquier reajuste de “ k ” éxitos y “ $n - k$ ” fracasos nos vale, luego: $PR_n^{k,n-k} = C_k^n = \binom{n}{k}$ con lo que concluimos: $P[\mathbb{X} = k] = \binom{n}{k} p^k \cdot q^{n-k}$

□

▷ Como depende de dos parámetros (“ n ” y “ p ”) la llamamos binomial de parámetros n y p y la notamos por $B(n, p)$. Como $\sum_{k=0}^n \binom{n}{k} p^k q^{n-k} = (p + q)^n = 1$ observamos que para el suceso seguro tenemos el binomio de Newton, de ahí el nombre de Binomial.

▷ **Función de distribución**: $F(x) = \sum_{k \leq x} \binom{n}{k} p^k q^{n-k}$ donde $x \in [0, n]$ y si $x < 0 \rightarrow F(x) = 0$ y si $x > n \rightarrow F(x) = 1$

▷ **Esperanza**: $E[\mathbb{X}] = n \cdot p$

$$Proof. E[\mathbb{X}] = \sum_{k=0}^n \binom{n}{k} k \cdot p^k q^{n-k} = \left(\sum_{k=1}^n \frac{(n-1)!}{(k-1)!(n-k)!} p^{k-1} q^{n-k} \right) \cdot np = n \cdot p(p + 1 - p)^{n-1} = n \cdot p$$

□

▷ **Varianza:** $\sigma^2[\mathbb{X}] = E[\mathbb{X}^2] - (E[\mathbb{X}])^2 = n \cdot p \cdot (1 - p) = n \cdot p \cdot q$

Proof. $E[\mathbb{X}^2] = E[\mathbb{X}(\mathbb{X} - 1)] + E[\mathbb{X}] = \sum_{k=0}^n \binom{n}{k} k(k-1) \cdot p^k q^{n-k} + np = n(n-1)p^2 + np \rightarrow$
 $\rightarrow \sigma^2[\mathbb{X}] = n(n-1)p^2 + np - n^2p^2 = n \cdot p \cdot (1 - p)$

□

▷ **Función generatriz de momentos:** $M(t) = [p \cdot e^t + (1 - p)]^n$

Proof. $E[e^{t\mathbb{X}}] = \sum_{k=0}^n \binom{n}{k} e^{tk} \cdot p^k q^{n-k} = \sum_{k=0}^n \binom{n}{k} (pe^t)^k \cdot (1 - p)^{n-k} = [p \cdot e^t + (1 - p)]^n$

□

▷ **Distribución multinomial:** es una generalización de la Binomial. Supongamos el espacio muestral $\Omega = \{A_1, \dots, A_s\}$ que consta de “s” sucesos con probabilidades p_1, \dots, p_s y tal que $p_1 + \dots + p_s = 1$. Supongamos que se realizan “n” pruebas. La probabilidad de que A_1 se repita k_1 veces, ..., A_s se repita k_s veces es:

$$\frac{n!}{k_1! \dots k_s!} \cdot p_1^{k_1} \dots p_s^{k_s}, \text{ tal que } k_1 + \dots + k_s = n$$

donde $\frac{n!}{k_1! \dots k_s!} = PR_n^{k_1, \dots, k_s}$.

Luego: $P[\{A_j = k_j\}, j = 1, \dots, s] = \frac{n!}{k_1! \dots k_s!} \cdot p_1^{k_1} \dots p_s^{k_s}$

▷ **Por ejemplo:** si lanzamos un dado de seis caras ocho veces, la probabilidad de obtener dos unos, dos cincos y el resto de las caras una vez es:

$$\frac{8!}{2!1!1!1!2!1!} \cdot \left(\frac{1}{6}\right)^2 \left(\frac{1}{6}\right) \left(\frac{1}{6}\right) \left(\frac{1}{6}\right) \left(\frac{1}{6}\right)^2 \left(\frac{1}{6}\right)$$

5) Distribución de Poisson:

▷ También llamada “Ley de los sucesos raros”. Se aplica en situaciones en se tiene una Binomial con $p \rightsquigarrow 0$ y $n \gg$ y donde $n \cdot p$ se mantiene constante a $\lambda > 0$. La distribución de probabilidad se obtiene haciendo el límite $n \rightarrow \infty$ de la Binomial.

$$\begin{aligned}
 \text{Proof. } P[\xi = k] &= \lim_{n \rightarrow \infty} \binom{n}{k} p^k (1-p)^{n-k} = \lim_{n \rightarrow \infty} \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} = \{n \cdot p = \lambda > 0\} = \\
 &= \lim_{n \rightarrow \infty} \frac{n!}{k!(n-k)!} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k} = \frac{\lambda^k}{k!} \lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n \left[\frac{1 \cdot \left(1 - \frac{1}{n}\right) \cdots \left(1 - \frac{k-1}{n}\right)}{\left(1 - \frac{\lambda}{n}\right)^k} \right] = \\
 &= \{ \text{el primer término tiende a } e^{-\lambda} \text{ y el segundo tiende a } 1 \} = \frac{\lambda^k}{k!} \cdot e^{-\lambda}
 \end{aligned}$$

□

▷ **Definición:** sea \mathbb{X} una v.a. discreta sobre Ω, \mathcal{A}, P). Se dice que $\mathbb{X} \sim \mathcal{P}(\lambda)$ es una v.a. de Poisson de parámetro $\lambda > 0$ si ξ toma los valores $0, 1, 2, \dots$ con probabilidades: $P[\xi = k] = e^{-\lambda} \frac{\lambda^k}{k!}$

▷ Es una distribución de probabilidad:

$$\text{Proof. } \sum_{k=0}^{\infty} P[\xi = k] = \sum_{k=0}^{\infty} e^{-\lambda} \frac{\lambda^k}{k!} = e^{-\lambda} \cdot e^{\lambda} = 1$$

□

La distribución de Poisson se aplica en situaciones como:

- 1) Número de radiaciones radioactivas
- 2) Número de partos triples por año
- 3) Número de llamadas telefónicas por minuto
- 4) Los primeros ejemplos aplicados fueron contando los muertos por cox en el ejército prusiano durante 20 años en 10 cuerpos de caballería.

▷ **Propiedades:**

- 1) Es asimétrica y cuando $\lambda \rightarrow \infty$ el coeficiente de apuntamiento se hace cero.
- 2) La distribución de Poisson, $\mathcal{P}(\lambda)$ se considera una buena aproximación a la $B(n, p)$ en el caso $n \cdot p < 5$ y $p < 0,1$ o $n > 100$ y $p < 0,05$. El interés de sustituir la Binomial por la Poisson radica en esta última depende de un solo parámetro, λ , mientras que la Binomial lo hace de dos: n y p .

▷ **Función de distribución:** $F(x) = \sum_{k \leq x} e^{-\lambda} \frac{\lambda^k}{k!}$

▷ **Esperanza:** $E[\mathbb{X}] = \lambda$

$$Proof. E[\mathbb{X}] = \sum_{k=0}^{\infty} \left(e^{-\lambda} \frac{\lambda^k}{k!} \right) \cdot k = e^{-\lambda} \lambda \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} = \lambda \cdot e^{-\lambda} \cdot e^{\lambda} = \lambda$$

□

▷ **Varianza:** $\sigma^2[\mathbb{X}] = \lambda$

$$Proof. E[\mathbb{X}^2] = \sum_{k=0}^{\infty} k^2 e^{-\lambda} \frac{\lambda^k}{k!} = E[\mathbb{X}(\mathbb{X}-1)] + E[\mathbb{X}] = \sum_{k=0}^{\infty} k(k-1) e^{-\lambda} \frac{\lambda^k}{k!} + \lambda = \lambda^2 e^{-\lambda} \sum_{k=2}^{\infty} \frac{\lambda^{k-2}}{(k-2)!} + \lambda = \\ = \lambda^2 e^{-\lambda} e^{\lambda} + \lambda = \lambda^2 + \lambda \\ \sigma^2[\mathbb{X}] = E[\mathbb{X}^2] - E[\mathbb{X}]^2 = \lambda^2 + \lambda - \lambda^2 = \lambda$$

□

▷ **Función generatriz de momentos:** $M(t) = e^{\lambda(e^t-1)}$

$$Proof. M(t) = E[e^{t\mathbb{X}}] = \sum_{k=0}^{\infty} e^{tk} e^{-\lambda} \frac{\lambda^k}{k!} = e^{-\lambda} \cdot \sum_{k=0}^{\infty} \frac{(e^t \lambda)^k}{k!} = e^{-\lambda} e^{e^t \lambda} = e^{\lambda(e^t-1)}$$

□

▷ **Función característica:** $\varphi_{\mathbb{X}}(t) = e^{\lambda(e^{it}-1)}$

$$Proof. \varphi_{\mathbb{X}}(t) = E[e^{i \cdot t \mathbb{X}}] = \sum_{k=0}^{\infty} e^{i \cdot tk} e^{-\lambda} \frac{\lambda^k}{k!} = e^{-\lambda} \cdot \sum_{k=0}^{\infty} \frac{(e^{i \cdot t} \lambda)^k}{k!} = e^{-\lambda} e^{e^{i \cdot t} \lambda} = e^{\lambda(e^{i \cdot t}-1)}$$

□

6) Además:

▷ Además de las contempladas aquí, existen otras distribuciones discretas como:

- 1) Distribución uniforme discreta
- 2) Distribución hipergeométrica
- 3) Distribución geométrica o de Pascal
- 4) Distribución binomial negativa
- 5) Etc.

▷ Por último, se podría acometer la aproximación de una distribución empírica por una distribución teórica: por ejemplo, si una variable estadística satisface “a priori” las condiciones de una Binomial, ¿cuál de las binomiales será la más próxima? Para ello se necesita considerar:

- a) Una medida en la distancia entre la empírica y la distribución ajustada
- b) Un medio de apreciar la distancia medida

▷ Se demuestra que, entre todas las binomiales, la que mejor se aproxima a una empírica de media \bar{x} , es la Binomial tal que $p = \frac{\bar{x}}{n}$. En el caso de la Poisson, el parámetro será la media: $\lambda = \bar{x}$