

Probabilidad y Estadística (Borradores, Curso 23)  
Ensayos Bernoulli y otras cositas

Sebastian Grynberg

25 - 27 de abril de 2011



Jakob Bernoulli (1654 - 1705)

*En la "buena" te encontré  
y en la "mala" te perdí ...*

(Enrique Cadícamo)

# Índice

<b>1. Ensayos Bernoulli</b>	<b>2</b>
1.1. La distribución binomial: cantidad de éxitos en $n$ ensayos . . . . .	4
1.2. Término central . . . . .	5
1.3. La distribución geométrica: tiempo de espera hasta el primer éxito . . . . .	6
1.4. La distribución Pascal: tiempo de espera hasta el $k$ -ésimo éxito . . . . .	8
<b>2. La distribución de Poisson</b>	<b>10</b>
2.1. Motivación 1: Mecánica Estadística. (De la estadística de Maxwell-Boltzmann a la distribución de Poisson) . . . . .	10
2.2. Motivación 2: Aproximación de Poisson de la distribución binomial . . . . .	12
2.3. La distribución Poisson . . . . .	14
2.4. La aproximación Poisson. (Técnica de acoplamiento) . . . . .	16
<b>3. Cuentas con exponenciales</b>	<b>20</b>
3.1. Motivación: pasaje de lo discreto a lo continuo . . . . .	20
3.2. Distribución exponencial . . . . .	21
3.3. Suma de exponenciales independientes de igual intensidad . . . . .	22
3.4. Caracterización cualitativa de la distribución exponencial . . . . .	23
3.5. Mínimos . . . . .	24
<b>4. Bibliografía consultada</b>	<b>26</b>

## 1. Ensayos Bernoulli

Se trata de ensayos repetidos en forma independiente en los que hay sólo dos resultados posibles, usualmente denominados “éxito” y “fracaso”, cuyas probabilidades,  $p$  y  $1 - p$ , se mantienen constantes a lo largo de todos los ensayos.

El espacio muestral de cada ensayo individual está formado por dos puntos  $S$  y  $F$ . El espacio muestral de  $n$  ensayos Bernoulli contiene  $2^n$  puntos o sucesiones de  $n$  símbolos  $S$  y  $F$ , cada punto representa un resultado posible del experimento compuesto. Como los ensayos son independientes las probabilidades se multiplican. En otras palabras, *la probabilidad de cada sucesión particular es el producto que se obtiene reemplazando los símbolos  $S$  y  $F$  por  $p$  y  $1 - p$ , respectivamente. Así,*

$$\mathbb{P}(SSFSS \dots FFS) = pp(1-p)p(1-p)\cdots(1-p)(1-p)p.$$

**Ejemplo 1.1.** Si repetimos en forma independiente un experimento aleatorio y estamos interesados en la ocurrencia del evento  $A$  al que consideramos “éxito”, tenemos ensayos Bernoulli con  $p = \mathbb{P}(A)$ . □

**Modelando ensayos Bernoulli.** Los ensayos Bernoulli (con probabilidad de éxito  $p$ ) se describen mediante una sucesión de variables aleatorias independientes e idénticamente distribuidas ( $X_i : i \in \mathbb{N}$ ) cada una con distribución Bernoulli( $p$ ),

$$\mathbb{P}(X_i = x_i) = p^{x_i}(1-p)^{1-x_i}, \quad x_i \in \{0, 1\}. \quad (1)$$

Esto es,  $\mathbb{P}(X_i = 1) = p$  y  $\mathbb{P}(X_i = 0) = 1 - p$ . En este contexto,  $X_i = 1$  significa que “el resultado del  $i$ -ésimo ensayo es éxito”.

**Construcción.** Dada la probabilidad de éxito  $p \in (0, 1)$ , las variables aleatorias que describen a los ensayos Bernoulli se pueden construir del siguiente modo: se considera una sucesión de variables aleatorias independientes  $U_i : i \in \mathbb{N}$ , cada una con distribución uniforme sobre el intervalo  $(0, 1]$  y se definen  $X_i := \mathbf{1}\{1 - p < U_i \leq 1\}$ .

**Preguntas elementales.** Se pueden formular varios tipos de preguntas relacionadas con los ensayos Bernoulli. Las más sencillas son las siguientes:

- (a) ¿Cuál es la cantidad total de éxitos en los primeros  $n$  ensayos?
- (b) ¿En  $n$  ensayos, cuál es el número de éxitos más probable?
- (c) ¿Cuánto “tiempo” hay que esperar para observar el primer éxito?
- (d) ¿Cuánto “tiempo” hay que esperar para observar el  $k$ -ésimo éxito?

En lo que sigue expresaremos las preguntas (a)-(d) en términos de las variables aleatorias  $X_i : i \in \mathbb{N}$  que describen los ensayos Bernoulli.

La *cantidad de éxitos en los primeros  $n$  ensayos* se describe mediante la suma de las primeras variables  $X_1, \dots, X_n$

$$S_n := \sum_{i=1}^n X_i. \quad (2)$$

La pregunta (a) interroga por la distribución de probabilidades de la variable aleatoria  $S_n$  definida en (2). Esto es, para cada  $k = 0, \dots, n$ , se trata de determinar cuánto valen las probabilidades  $\mathbb{P}(S_n = k)$ . En cambio, la pregunta (b) interroga por el valor de  $k$  que maximiza a la función de  $k$ ,  $\mathbb{P}(S_n = k)$ .

El *tiempo de espera hasta el primer éxito* se describe mediante la variable aleatoria

$$T_1 := \min\{i \in \mathbb{N} : X_i = 1\}, \quad (3)$$

y en general, el *tiempo de espera hasta el  $k$ -ésimo éxito*,  $k \geq 1$  se describe, recursivamente, mediante

$$T_k := \min\{i > T_{k-1} : X_i = 1\}. \quad (4)$$

La pregunta (c) interroga por la distribución de probabilidades de la variable  $T_1$  definida en (3): cuánto valen las probabilidades  $\mathbb{P}(T_1 = n)$ ,  $n \in \mathbb{N}$ ? Finalmente, la pregunta (d) interroga por la distribución de probabilidades de las variables  $T_k$ ,  $k \geq 2$ , definidas en (4): cuánto valen las probabilidades  $\mathbb{P}(T_k = n)$ ,  $n \geq k$ ?

### 1.1. La distribución binomial: cantidad de éxitos en $n$ ensayos

La cantidad de éxitos puede ser  $0, 1, \dots, n$ . El primer problema es determinar las correspondientes probabilidades. El evento *en  $n$  ensayos resultaron  $k$  éxitos y  $n - k$  fracasos*

$$\left\{ (X_1, \dots, X_n) = (x_1, \dots, x_n) : \sum_{i=1}^n x_i = k \right\}$$

puede ocurrir de tantas formas distintas como  $k$  símbolos 1 se puedan ubicar en  $n$  lugares. En otras palabras, el evento considerado contiene  $\binom{n}{k}$  puntos, cada uno de probabilidad

$$\begin{aligned} \mathbb{P}\left(\bigcap_{i=1}^n \{X_i = x_i\}\right) &= \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} = p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \\ &= p^k (1-p)^{n-k}. \end{aligned}$$

Por lo tanto,

$$\mathbb{P}(S_n = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad 0 \leq k \leq n. \quad (5)$$

En particular, la probabilidad de que no ocurra ningún éxito en  $n$  ensayos es  $(1-p)^n$ , y la probabilidad de que ocurra al menos un éxito es  $1 - (1-p)^n$ .

La distribución de  $S_n$ , determinada en (5), se denomina *la distribución binomial de parámetros  $n$  y  $p$*  y se denota  $\text{Binomial}(n, p)$ .

**Nota Bene.** Por definición, la distribución binomial de parámetros  $n$  y  $p$  es *la distribución de una suma de  $n$  variables aleatorias independientes cada con distribución Bernoulli de parámetro  $p$* .

**Ejemplo 1.2.** Se tira un dado equilibrado 11 veces y en cada tiro se apuesta al 6, ¿cuál es la probabilidad de ganar exactamente 2 veces? Como el dado es equilibrado, la probabilidad de éxito es  $1/6$  y la cantidad de éxitos en 11 tiros tiene distribución Binomial  $(11, 1/6)$ . Por lo tanto, la probabilidad requerida es

$$\binom{11}{2} \left(\frac{1}{6}\right)^2 \left(\frac{5}{6}\right)^9 = 0.2960 \dots$$

□

**Ejemplo 1.3.** Cada artículo producido por una máquina será defectuoso con probabilidad 0.1, independientemente de los demás. En una muestra de 3, ¿cuál es la probabilidad de encontrar a lo sumo un defectuoso?

Si  $X$  es la cantidad de artículos defectuosos en la muestra, entonces  $X \sim \text{Binomial}(3, 0.1)$ . En consecuencia,

$$\mathbb{P}(X \leq 1) = \mathbb{P}(X = 0) + \mathbb{P}(X = 1) = \binom{3}{0} (0.1)^0 (0.9)^3 + \binom{3}{1} (0.1)^1 (0.9)^2 = 0.972.$$

□

**Ejemplo 1.4.** Un avión se mantendrá en vuelo mientras funcionen al menos el 50% de sus motores. Si cada motor del avión en vuelo puede fallar con probabilidad  $1 - p$  independientemente de los demás, ¿para cuáles valores de  $p \in (0, 1)$  es más seguro un avión de 4 motores que uno de 2?

Como cada motor puede fallar o funcionar independientemente de los demás, la cantidad de motores que siguen funcionando es una variable aleatoria con distribución binomial. La probabilidad de que un avión de 4 motores realice un vuelo exitoso es

$$\binom{4}{2}p^2(1-p)^2 + \binom{4}{3}p^3(1-p) + \binom{4}{4}p^4 = 6p^2(1-p)^2 + 4p^3(1-p) + p^4,$$

mientras que la correspondiente probabilidad para un avión de 2 motores es

$$\binom{2}{1}p(1-p) + \binom{2}{2}p^2 = 2p(1-p) + p^2.$$

En consecuencia, el avión de 4 motores es más seguro que el de 2 si

$$6p^2(1-p)^2 + 4p^3(1-p) + p^4 > 2p(1-p) + p^2$$

lo que es equivalente a las siguientes expresiones simplificadas

$$3p^3 - 8p^2 + 7p - 2 > 0 \iff 3(p - 2/3)(p - 1)^2 > 0 \iff p > 2/3.$$

Por lo tanto, el avión de 4 motores es más seguro cuando la probabilidad de que cada motor se mantenga en funcionamiento es mayor que  $2/3$ , mientras que el avión de 2 motores es más seguro cuando esa probabilidad es menor que  $2/3$ .  $\square$

**Ejemplo 1.5.** Si la probabilidad de éxito es  $p = 0.01$ , cuántos ensayos se deben realizar para asegurar que la probabilidad de que ocurra por lo menos un éxito sea al menos  $1/2$ ?

Buscamos el menor entero  $n$  tal que  $1 - (0.99)^n \geq \frac{1}{2}$ , o equivalentemente  $\frac{1}{2} \geq (0.99)^n$ . Tomando logaritmos  $-\log 2 \geq n \log(0.99)$  y despejando  $n$  resulta  $n \geq -\log(2)/\log(0.99) \approx 68.96$ . Por lo tanto,  $n = 69$ .  $\square$

## 1.2. Término central

De la fórmula (5) se puede ver que

$$\begin{aligned} \frac{\mathbb{P}(S_n = k)}{\mathbb{P}(S_n = k - 1)} &= \frac{\binom{n}{k}p^k(1-p)^{n-k}}{\binom{n}{k-1}p^{k-1}(1-p)^{n-k+1}} = \frac{(k-1)!(n-k+1)!p}{k!(n-k)!(1-p)} \\ &= \frac{(n-k+1)p}{k(1-p)} = 1 + \frac{(n+1)p - k}{k(1-p)}. \end{aligned} \quad (6)$$

De (6) se deduce que  $\mathbb{P}(S_n = k)$  crece cuando  $k < (n+1)p$  y decrece cuando  $k > (n+1)p$ . Si  $(n+1)p$  es un número entero, entonces  $\mathbb{P}(S_n = (n+1)p) = \mathbb{P}(S_n = (n+1)p - 1)$ . En

otras palabras, la cantidad más probable de éxitos en  $n$  ensayos es  $m := \lfloor (n+1)p \rfloor$ . Salvo en el caso en que  $m = (n+1)p$ , donde también lo es  $m - 1$ .

Cuando  $p = \frac{1}{2}$  el resultado anterior se puede observar directamente en el triángulo de Pascal: en el centro de las filas pares está el máximo. En la región central de las filas impares hay dos máximos.

**Ejemplo 1.6.** Se tira un dado equilibrado  $n$  veces y en cada tiro se apuesta al 6. ¿Cuál es la cantidad más probable de éxitos cuando  $n = 12$ ? y cuando  $n = 11$ ?

La cantidad de éxitos tiene distribución Binomial  $(n, p)$ , donde  $p = 1/6$ . Cuando  $n = 12$ ,  $(n+1)p = 13/6 = 2.16\dots$  y entonces la cantidad más probable de éxitos es  $m = 2$ . Cuando  $n = 11$ ,  $(n+1)p = 2$  y entonces la cantidad más probable de éxitos es  $m = 1$  o  $m = 2$ . Ver la Figura 1.




Figura 1: (a) probabilidades binomiales  $(12, 1/6)$  (b) probabilidades binomiales  $(11, 1/6)$ .

□

### 1.3. La distribución geométrica: tiempo de espera hasta el primer éxito

El tiempo que hay que esperar para observar el primer éxito en una sucesión de ensayos Bernoulli puede ser  $n = 1, 2, \dots$ . El evento  $T_1 = 1$  significa que se obtuvo éxito en el primer ensayo y tiene probabilidad  $p$ . Para cada  $n \geq 2$ , el evento  $T_1 = n$  significa que en los primeros  $n - 1$  ensayos se obtuvieron fracasos y que en el  $n$ -ésimo se obtuvo éxito, lo que tiene probabilidad  $(1 - p)^{n-1}p$ . Por lo tanto, la distribución de  $T_1$  es

$$\mathbb{P}(T_1 = n) = (1 - p)^{n-1}p, \quad n \in \mathbb{N}. \quad (7)$$

El evento  $T_1 > n$  significa que los primeros  $n$  ensayos de la sucesión resultaron fracaso. Por lo tanto,

$$\mathbb{P}(T_1 > n) = (1 - p)^n, \quad n \geq 1. \quad (8)$$

La distribución de  $T_1$  se denomina *distribución geométrica de parámetro  $p$*  y se designa mediante  $\text{Geom}(p)$ .

**Ejemplo 1.7.** Se arroja repetidamente un dado. Cuál es la probabilidad de que el primer as aparezca antes del quinto tiro?. Suponiendo que el dado es perfecto, la probabilidad de obtener as es  $1/6$  y la cantidad de tiros hasta obtener el primer as tiene distribución  $\text{Geom}(1/6)$ . Por lo tanto, la probabilidad requerida es

$$1/6 + (5/6)(1/6) + (5/6)^2(1/6) + (5/6)^3(1/6) = (1/6) \left( \frac{1 - (5/6)^4}{1 - (5/6)} \right) = 1 - (5/6)^4 = 0.5177 \dots$$

□

**Ejemplo 1.8** (Ocurrencias casi seguras). Si al realizarse un experimento aleatorio un evento  $A$  tiene probabilidad positiva de ocurrir, entonces en una sucesión de experimentos independientes el evento  $A$  ocurrirá *casi seguramente*.

En efecto, el tiempo de espera hasta que ocurra el evento  $A$  es una variable aleatoria  $T_A$  con distribución geométrica de parámetro  $p = \mathbb{P}(A)$ . Si se observa que

$$\{T_A > 1\} \supseteq \{T_A > 2\} \supseteq \{T_A > 3\} \supseteq \dots$$

y que

$$\{T_A = \infty\} = \bigcap_{n \geq 1} \{T_A > n\}$$

y se usa la propiedad de continuidad de  $\mathbb{P}$ , se obtiene que

$$\mathbb{P}(T_A = \infty) = P \left( \bigcap_{n \geq 1} \{T_A > n\} \right) = \lim_{n \rightarrow \infty} \mathbb{P}(T_A > n) = \lim_{n \rightarrow \infty} (1 - p)^n = 0.$$

Por lo tanto,  $\mathbb{P}(T_A < \infty) = 1$ .

□

### Pérdida de memoria

La variable aleatoria,  $T$ , con distribución geométrica de parámetro  $p$  tiene la propiedad de *pérdida de memoria*,

$$\mathbb{P}(T > n + m | T > n) = \mathbb{P}(T > m) \quad n, m \in \mathbb{N} \quad (9)$$

La identidad (9) se obtiene de (8) y de la fórmula de probabilidad condicional:

$$\begin{aligned}\mathbb{P}(T > n + m | T > n) &= \frac{\mathbb{P}(T > n + m, T > n)}{\mathbb{P}(T > n)} \\ &= \frac{\mathbb{P}(T > n + m)}{\mathbb{P}(T > n)} = \frac{(1 - p)^{n+m}}{(1 - p)^n} \\ &= (1 - p)^m = \mathbb{P}(T > m).\end{aligned}$$

De hecho, la propiedad de pérdida de memoria definida en (9) caracteriza a la distribución geométrica.

**Teorema 1.9.** Si  $T$  es una variable aleatoria a valores en  $\mathbb{N}$  con la propiedad de pérdida de memoria, entonces  $T \sim \text{Geom}(p)$ , donde  $p = \mathbb{P}(T = 1)$ .

**Demostración.** Sea  $G(n) := \mathbb{P}(T > n)$ . Si  $T$  pierde memoria, tenemos que

$$G(n + m) = G(n)G(m) \tag{10}$$

De (10) sigue que  $G(2) = G(1)G(1) = G(1)^2$ ,  $G(3) = G(2)G(1) = G(1)^3$  y en general  $G(n) = G(1)^n$  cualquiera sea  $n \in \mathbb{N}$ . En otros términos, la distribución de  $T$  es tal que

$$\mathbb{P}(T > n) = G(1)^n.$$

Por lo tanto,

$$\mathbb{P}(T = n) = \mathbb{P}(T > n - 1) - \mathbb{P}(T > n) = G(1)^{n-1} - G(1)^n = G(1)^{n-1}(1 - G(1)).$$

□

#### 1.4. La distribución Pascal: tiempo de espera hasta el $k$ -ésimo éxito

Para observar  $k$ -éxitos en una sucesión de ensayos Bernoulli, lo mínimo que hay que esperar es  $k$  ensayos. ¿Cuándo ocurre el evento  $T_k = n$ ,  $n \geq k$ ? El  $n$ -ésimo ensayo debe ser éxito y en los  $n - 1$  ensayos anteriores deben ocurrir exactamente  $k - 1$  éxitos. Hay  $\binom{n-1}{k-1}$  formas distintas de ubicar  $k - 1$  símbolos 1 en  $n - 1$  lugares. Por lo tanto,

$$\mathbb{P}(T_k = n) = \binom{n-1}{k-1} p^k (1-p)^{n-k} \quad n \geq k. \tag{11}$$

La distribución de  $T_k$  se denomina *distribución Pascal de parámetros  $k$  y  $p$*  y se designa mediante  $\text{Pascal}(k, p)$ .

*La distribución Pascal de parámetros  $k$  y  $p$  es la distribución de una suma de  $k$  variables aleatorias independientes cada una con ley  $\text{Geom}(p)$ .* Lo cual es intuitivamente claro si se piensa en el modo que arribamos a su definición.



En efecto, definiendo  $T_0 := 0$  vale que

$$T_k = \sum_{i=1}^k (T_i - T_{i-1}).$$

Basta ver que para cada  $i = 1, \dots, k$  las diferencias  $T_i - T_{i-1}$  son independientes y todas se distribuyen como  $T_1 \sim \text{Geom}(p)$ .

En lo que sigue mostraremos que  $T_1$  y  $T_2 - T_1$  son independientes y que  $T_2 - T_1 \sim \text{Geom}(p)$ .

$$\begin{aligned} \mathbb{P}(T_1 = n, T_2 - T_1 = m) &= \mathbb{P}(T_2 - T_1 = m | T_1 = n) \mathbb{P}(T_1 = n) \\ &= \mathbb{P}(T_2 = m + n | T_1 = n) \mathbb{P}(T_1 = n) \end{aligned}$$

El evento  $T_1 = n$  depende de  $X_1, \dots, X_n$ . Si se sabe que  $T_1 = n$ , el evento  $T_2 = m + n$  depende de  $X_{n+1}, \dots, X_{n+m}$ . Por definición,

$$\mathbb{P}(T_2 = n + m | T_1 = n) = (1 - p)^{m-1} p.$$

En consecuencia,

$$\begin{aligned} \mathbb{P}(T_1 = n, T_2 - T_1 = m) &= \mathbb{P}(T_1 = n) \mathbb{P}(T_2 = m + n | T_1 = n) \\ &= (1 - p)^{n-1} p (1 - p)^{m-1} p. \end{aligned}$$

De la factorización anterior se deduce que  $T_1$  y  $T_2 - T_1$  son independientes y que cada una tiene distribución geométrica de parámetro  $p$ .  $\square$

**Ejemplo 1.10.** Lucas y Monk disputan la final de un campeonato de ajedrez. El primero que gane 6 partidas (no hay tablas) resulta ganador. La probabilidad de que Lucas gane cada partida es  $3/4$ . Cuál es la probabilidad de que Lucas gane el campeonato en la novena partida? La cantidad de partidas que deben jugarse hasta que Lucas gane el campeonato tiene distribución Pascal( $6, 3/4$ ). Por lo tanto, la probabilidad requerida es

$$\binom{8}{5} \left(\frac{3}{4}\right)^6 \left(\frac{1}{4}\right)^3 = 0.1557\dots$$

$\square$

**Ejemplo 1.11.** En una calle hay tres parquímetros desocupados. Se estima que los próximos 10 minutos pasarán 6 coches por esa calle y, en media, el 80 % tendrá que estacionarse en alguno de ellos. Calcular la probabilidad de que los tres parquímetros sean ocupados en los próximos 10 minutos.

La probabilidad requerida es la probabilidad de que la cantidad,  $N$ , de ensayos hasta el tercer éxito sea menor o igual que 6. Como  $N$  tiene distribución Pascal( $3, 0.8$ ) resulta

que

$$\begin{aligned}
 \mathbb{P}(N \leq 6) &= \sum_{n=3}^6 \mathbb{P}(N = n) = \sum_{n=3}^6 \binom{n-1}{2} (0.8)^3 (0.2)^{n-3} \\
 &= (0.8)^3 \left[ \binom{2}{2} (0.2)^0 + \binom{3}{2} (0.2)^1 + \binom{4}{2} (0.2)^2 + \binom{5}{2} (0.2)^3 \right] \\
 &= (0.8)^3 [1 + 3(0.2) + 6(0.2)^2 + 10(0.2)^3] \\
 &= 0.983 \dots
 \end{aligned}$$

Notar que una forma alternativa de obtener el mismo resultado es sumar las probabilidades de observar 3, 4, 5, 6 éxitos en 6 ensayos Bernoulli.  $\square$

**Nota Bene: Relación entre las distribuciones Binomial y Pascal.** Sean  $S_n \sim \text{Binomial}(n, p)$  y  $T_k \sim \text{Pascal}(k, p)$ . Vale que

$$\mathbb{P}(S_n \geq k) = \mathbb{P}(T_k \leq n). \quad (12)$$

En efecto, decir que en  $n$  ensayos Bernoulli ocurren por lo menos  $k$  éxitos es lo mismo que decir que el tiempo de espera hasta observar el  $k$ -ésimo éxito no supera a  $n$ .  $\square$

## 2. La distribución de Poisson

### 2.1. Motivación 1: Mecánica Estadística. (De la estadística de Maxwell-Boltzmann a la distribución de Poisson)

*Estadística de Maxwell-Boltzmann.* El espacio se divide en una gran cantidad,  $n$ , de pequeñas regiones llamadas celdas y se considera un sistema mecánico compuesto por  $r$  partículas independientes que se distribuyen al azar y entre las  $n$  celdas. ¿Cómo se distribuye la cantidad de partículas en la celda 1?

Como se supone que todas las partículas son distintas y que todas las ubicaciones de las partículas son igualmente probables. La cantidad de partículas en la celda 1 se distribuye como una Binomial  $(r, 1/n)$ . Por lo tanto, si  $p_k$  designa la probabilidad de que la celda 1 contenga exactamente  $k$  partículas, tenemos que

$$p_k = \binom{r}{k} \left(\frac{1}{n}\right)^k \left(1 - \frac{1}{n}\right)^{r-k}. \quad (13)$$

En particular, la probabilidad  $p_0$  de que una celda dada no contenga partículas es

$$p_0 = \left(1 - \frac{1}{n}\right)^r. \quad (14)$$

En consecuencia, si  $n \rightarrow \infty$  y  $r \rightarrow \infty$  de modo tal que  $r/n \rightarrow \lambda$  se obtiene que

$$p_0 \rightarrow e^{-\lambda}.$$

El número  $\lambda$  caracteriza la “*densidad promedio*” de las partículas. En general, usando la fórmula de Stirling:  $n! \sim \sqrt{2\pi} n^{n+\frac{1}{2}} e^{-n}$ , se puede ver que cuando  $n \rightarrow \infty$  y  $r \rightarrow \infty$  de modo tal que  $r/n \rightarrow \lambda$  se obtiene que

$$p_k \rightarrow e^{-\lambda} \frac{\lambda^k}{k!}.$$

Dicho en palabras, la *forma límite* de la estadística de Maxwell-Boltzmann es la *distribución de Poisson de intensidad*  $\lambda$  definida por

$$p(k) := e^{-\lambda} \frac{\lambda^k}{k!}, \quad k = 0, 1, 2, \dots$$

□

**Problemas de ocupación.** Se distribuyen  $r$  bolas entre  $n$  cajas y cada una de las  $n^r$  posibles configuraciones tiene probabilidad  $n^{-r}$ .

1. La probabilidad  $p_k$  que una caja dada contenga exactamente  $k$  bolas está dada por la distribución binomial. El número más probable es el entero  $\nu$  tal que  $(r - n + 1)/n < \nu \leq (r + 1)/n$ . (En otras palabras, se afirma que  $p_0 < p_1 < \dots < p_{\nu-1} \leq p_\nu > p_{\nu+1} > \dots > p_r$ )

**Fórmula de Stirling.** [Ver Feller I, p.52]

$$n! \sim \sqrt{2\pi} n^{n+\frac{1}{2}} e^{-n},$$

donde el signo  $\sim$  se usa para indicar que el cociente de los dos lados tiende a 1 cuando  $n \rightarrow \infty$

2. ☞ Utilizando la fórmula de Stirling demostrar que

$$\lim_{n \rightarrow \infty} \binom{n}{k} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k} = \frac{\lambda^k}{k!} e^{-\lambda}.$$

3. *Forma límite.* Si  $n \rightarrow \infty$  y  $r \rightarrow \infty$  de modo tal que que la cantidad de bolas por caja  $r/n \rightarrow \lambda$ , entonces

$$p_k \rightarrow e^{-\lambda} \frac{\lambda^k}{k!}.$$

## 2.2. Motivación 2: Aproximación de Poisson de la distribución binomial

En diversas aplicaciones tenemos que tratar con ensayos Bernoulli donde, para decirlo de algún modo,  $n$  es grande y  $p$  es pequeño, mientras que el producto  $\lambda = np$  es moderado. En tales casos conviene usar una aproximación de las probabilidades  $\mathbb{P}(S_n = k)$ , donde  $S_n \sim \text{Binomial}(n, p)$  y  $p = \lambda/n$ . Para  $k = 0$  tenemos

$$\mathbb{P}(S_n = 0) = (1 - p)^n = \left(1 - \frac{\lambda}{n}\right)^n. \quad (15)$$

Tomando logaritmos y usando el desarrollo de Taylor,

$$\log(1 - t) = -t - \frac{1}{2}t^2 - \frac{1}{3}t^3 - \frac{1}{4}t^4 - \dots,$$

se obtiene

$$\log \mathbb{P}(S_n = 0) = n \left(1 - \frac{\lambda}{n}\right) = -\lambda - \frac{\lambda^2}{2n} - \dots \quad (16)$$

En consecuencia, para  $n$  grande se tiene que

$$\mathbb{P}(S_n = 0) \approx e^{-\lambda}, \quad (17)$$

donde el signo  $\approx$  se usa para indicar una igualdad aproximada (en este caso de orden de magnitud  $1/n$ ). Más aún, usando la identidad (6) se puede ver que para cada  $k$  fijo y  $n$  suficientemente grande

$$\frac{\mathbb{P}(S_n = k)}{\mathbb{P}(S_n = k - 1)} = \frac{(n - k + 1)p}{k(1 - p)} \approx \frac{\lambda}{k}. \quad (18)$$

Recursivamente se concluye que

$$\begin{aligned} \mathbb{P}(S_n = 1) &\approx \lambda \cdot \mathbb{P}(S_n = 0) \approx \lambda e^{-\lambda}, \\ \mathbb{P}(S_n = 2) &\approx \frac{\lambda}{2} \cdot \mathbb{P}(S_n = 1) \approx \frac{\lambda^2}{2} e^{-\lambda}, \end{aligned}$$

y en general

$$\mathbb{P}(S_n = k) \approx \frac{\lambda^k}{k!} e^{-\lambda}. \quad (19)$$

La igualdad aproximada (19) se llama *la aproximación de Poisson de la distribución binomial*.




Figura 2: Comparación de las funciones de probabilidad de las distribuciones Binomial(10, 1/5) (bolita negra) y Poisson(2) (cuadradillo vacío).

**Otro modo de obtener el mismo resultado.**

$$\mathbb{P}(S_n = k) = \binom{n}{k} p^k (1-p)^{n-k} \sim \frac{1}{k!} \left( \frac{np}{1-p} \right)^k (1-p)^{n-k} \rightarrow \frac{\lambda^k}{k!} e^{-\lambda}.$$

**Ejemplo 2.1** (Artículos defectuosos). Una industria produce tornillos. Supongamos que la probabilidad de que un tornillo resulte defectuoso sea  $p = 0.015$ , entonces la probabilidad de que una caja de 100 tornillos no contenga ninguno defectuoso es  $(0.985)^{100} = 0.2206\dots$  La aproximación de Poisson es  $e^{-1.5} = 0.2231\dots$  y es suficientemente próxima para la mayoría de los propósitos prácticos. Si se pregunta: Cuántos tornillos debería contener la caja para que la probabilidad de encontrar al menos 100 tornillos sin defectos sea 0.8 o mejor? Si  $100 + x$  es el número buscado, entonces  $x$  es un número pequeño. Para aplicar la aproximación de Poisson para  $n = 100 + x$  ensayos debemos poner  $\lambda = np$ , pero  $np$  es aproximadamente  $100p = 1.5$ . Buscamos el menor entero  $x$  para el cual

$$e^{-1.5} \left( 1 + \frac{1.5}{1} + \dots + \frac{(1.5)^x}{x!} \right) \geq 0.8 \tag{20}$$

Para  $x = 1$  el valor del lado izquierdo de la inecuación (20) es aproximadamente 0.558, para  $x = 2$  es aproximadamente 0.809. Por lo tanto, la aproximación de Poisson permite concluir que se necesitan 102 tornillos. En realidad la probabilidad de encontrar al menos 100 tornillos sin defectos en una caja de 102 es  $0.8022\dots$  □

### 2.3. La distribución Poisson

Una variable aleatoria  $N$  tiene distribución Poisson( $\lambda$ ) si sus posibles valores son los enteros no negativos y si

$$\mathbb{P}(N = n) = e^{-\lambda} \frac{\lambda^n}{n!}, \quad n = 0, 1, \dots \quad (21)$$

El parámetro  $\lambda$  puede ser cualquier número positivo y la identidad

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

muestra que  $\lambda$  es la media de la distribución Poisson( $\lambda$ ):  $\mathbb{E}[N] = \lambda$ .

Se puede ver, sumando la serie, que

$$\mathbb{E}[N(N-1)] = \lambda^2$$

de donde se puede deducir que

$$\mathbb{E}[N^2] = \lambda + \lambda^2, \quad \mathbb{V}(N) = \lambda.$$

El rasgo más importante de la distribución Poisson es su aditividad.

**Teorema 2.2** (Aditividad). *Si  $N_1$  y  $N_2$  son variables aleatorias independientes con distribución Poisson de medias  $\lambda_1$  y  $\lambda_2$ , respectivamente. Entonces,*

$$N_1 + N_2 \sim \text{Poisson}(\lambda_1 + \lambda_2).$$

**Demostración.**

$$\begin{aligned} \mathbb{P}(N_1 + N_2 = n) &= \sum_{m=0}^n \mathbb{P}(N_1 = m, N_2 = n - m) = \sum_{m=0}^n \mathbb{P}(N_1 = m) \mathbb{P}(N_2 = n - m) \\ &= \sum_{m=0}^n e^{-\lambda_1} \frac{\lambda_1^m}{m!} e^{-\lambda_2} \frac{\lambda_2^{n-m}}{(n-m)!} = \frac{e^{-(\lambda_1 + \lambda_2)}}{n!} \sum_{m=0}^n \binom{n}{m} \lambda_1^m \lambda_2^{n-m} \\ &= e^{-(\lambda_1 + \lambda_2)} \frac{(\lambda_1 + \lambda_2)^n}{n!}. \end{aligned}$$

□

**Nota Bene.** El resultado del Teorema 2.2 se extiende por inducción a la suma de una cantidad finita de variables aleatorias independientes con distribución Poisson.

**Teorema 2.3** (Competencia). Sean  $N_1, N_2, \dots, N_m$  variables aleatorias independientes, cada  $N_j$  con distribución Poisson de media  $\lambda_j$ , respectivamente. Sea  $S = N_1 + \dots + N_m$ . Entonces, para cada  $n \geq 1$  vale que

$$(N_1, N_2, \dots, N_m) | S = n \sim \text{Multinomial} \left( n, \frac{\lambda_1}{\lambda}, \frac{\lambda_2}{\lambda}, \dots, \frac{\lambda_m}{\lambda} \right),$$

donde  $\lambda = \sum_j \lambda_j$ . En particular,

$$\mathbb{P}(N_j = 1 | S = 1) = \frac{\lambda_j}{\lambda}.$$

**Demostración.** La suma  $S = N_1 + \dots + N_m$  tiene distribución Poisson de media  $\lambda = \sum_j \lambda_j$ ; y entonces siempre que  $n_1 + \dots + n_m = n$ ,

$$\begin{aligned} \mathbb{P}(N_1 = n_1, \dots, N_m = n_m | S = n) &= \frac{\mathbb{P}(N_1 = n_1, \dots, N_m = n_m)}{\mathbb{P}(S = n)} \\ &= \prod_j \left( e^{-\lambda_j} \frac{\lambda_j^{n_j}}{n_j!} \right) \bigg/ \left( e^{-\lambda} \frac{\lambda^n}{n!} \right) \\ &= \frac{n!}{n_1! n_2! \dots n_m!} \prod_j \left( \frac{\lambda_j}{\lambda} \right)^{n_j}. \end{aligned}$$

□

**Nota Bene.** En el caso particular  $n = 2$ , el resultado del Teorema 2.3 se reduce a que, si  $N_1$  y  $N_2$  son variables aleatorias independientes con distribución Poisson de medias  $\lambda_1$  y  $\lambda_2$ , respectivamente, entonces, dado que  $N_1 + N_2 = n$ , la distribución condicional de  $N_1$  es Binomial( $n, p$ ), donde  $p = \frac{\lambda_1}{\lambda_1 + \lambda_2}$ . □

**Teorema 2.4** (Adelgazamiento). Sea  $N$  una variable aleatoria Poisson de media  $\lambda$ . Sea  $M$  una variable aleatoria tal que, dada  $N$ , tiene distribución Binomial( $N, p$ ), i.e.,

$$M | N = n \sim \text{Binomial}(n, p).$$

Entonces,  $M$  y  $N - M$  son variables aleatorias independientes con distribución Poisson de medias  $p\lambda$  y  $(1 - p)\lambda$ , respectivamente.

**Demostración.** Sean  $m, k \geq 0$

$$\begin{aligned} \mathbb{P}(M = m, N - M = k) &= \mathbb{P}(M = m, N - M = k | N = m + k) \mathbb{P}(N = m + k) \\ &= \mathbb{P}(M = m | N = m + k) \mathbb{P}(N = m + k) \\ &= \left( \binom{m+k}{m} p^m (1-p)^k \right) e^{-\lambda} \frac{\lambda^{m+k}}{(m+k)!} \\ &= \left( e^{-p\lambda} \frac{(p\lambda)^m}{m!} \right) \left( e^{-(1-p)\lambda} \frac{((1-p)\lambda)^k}{k!} \right). \end{aligned}$$

□

### Ejercicios adicionales

4. Sea  $N$  una variable aleatoria con distribución Poisson de media  $\lambda$ . Mostrar que

$$\mathbb{P}(N = n) = \frac{\lambda}{n} \mathbb{P}(N = n - 1), \quad n = 1, 2, \dots$$

Usar ese resultado para encontrar el valor de  $n$  para el cual  $\mathbb{P}(N = n)$  es maximal.

5.  $\diamond$  Se lanza una moneda una cantidad aleatoria  $N$  de veces, donde  $N$  tiene distribución Poisson. Sean  $N_1$  y  $N_2$  la cantidad de total de caras y de cecas observadas, respectivamente. Mostrar que las variables aleatorias  $N_1$  y  $N_2$  son independientes y que tienen distribución Poisson.

6. Sea  $X_1, X_2, \dots$  una sucesión de variables aleatorias independientes, cada una con distribución Bernoulli( $p$ ). Para cada  $n \geq 1$  se define  $S_n := \sum_{i=1}^n X_i$ . Por convención,  $S_0 := \sum_{i=1}^0 X_i = 0$ . Sea  $N$  una variable aleatoria con distribución Poisson( $\lambda$ ). Mostrar que

$$S_N \sim \text{Poisson}(p\lambda).$$

## 2.4. La aproximación Poisson. (Técnica de acoplamiento)

En lo que sigue mostraremos que cuando se consideran una gran cantidad de eventos independientes y cada uno de ellos tiene una probabilidad muy pequeña de ocurrir, la cantidad de tales eventos que realmente ocurre tiene una distribución “cercana” a la distribución Poisson.

### Construcción conjunta de variables Bernoulli y Poisson (Acoplamiento).

Para cada  $p \in [0, 1]$  dividimos el intervalo  $[0, 1]$  en dos intervalos

$$I_0(p) = [0, 1 - p), \quad I_1(p) = [1 - p, 1) \quad (22)$$

y en la sucesión de intervalos

$$J_0(p) = [0, e^{-p}), \quad J_k(p) = \left[ \sum_{j=0}^{k-1} e^{-p} \frac{p^j}{j!}, \sum_{j=0}^k e^{-p} \frac{p^j}{j!} \right), \quad k = 1, 2, \dots \quad (23)$$

Consideramos una variable aleatoria  $U$  con distribución  $\mathcal{U}[0, 1]$  y construimos dos variables aleatorias  $V$  y  $W$  con distribuciones Bernoulli( $p$ ) y Poisson( $p$ ), respectivamente:

$$V := \mathbf{1}\{U \in I_1(p)\}, \quad W := \sum_{k=0}^{\infty} k \mathbf{1}\{U \in J_k(p)\}. \quad (24)$$






Figura 3: Comparación de las funciones de probabilidad de las distribuciones Bernoulli(1/4) (bolita negra) y Poisson(1/4) (cuadradillo vacío)

De la desigualdad  $1 - p \leq e^{-p}$  resulta que  $I_0(p) \subset J_0(p)$  y que  $J_1(p) \subset I_1(p)$  (Ver el diagrama). En consecuencia,  $V = W \iff U \in I_0(p) \cup J_1(p)$ . Por ende,

$$\mathbb{P}(V = W) = \mathbb{P}(U \in I_0(p) \cup J_1(p)) = 1 - p + e^{-p}p, \quad (25)$$

y en consecuencia,

$$\mathbb{P}(V \neq W) = p - e^{-p}p = p(1 - e^{-p}) \leq p^2. \quad (26)$$

Usando la desigualdad (26) pueden obtenerse las siguientes cotas:

$$\sup_{k \geq 0} |\mathbb{P}(V = k) - \mathbb{P}(W = k)| \leq p^2, \quad (27)$$

$$\sum_k |\mathbb{P}(V = k) - \mathbb{P}(W = k)| \leq 2p^2. \quad (28)$$

La cota (27) se deduce de observar que

$$\begin{aligned} |\mathbb{P}(V = k) - \mathbb{P}(W = k)| &= |\mathbb{E}[\mathbf{1}\{V = k\}] - \mathbb{E}[\mathbf{1}\{W = k\}]| \\ &= |\mathbb{E}[\mathbf{1}\{V = k\} - \mathbf{1}\{W = k\}]| \\ &\leq \mathbb{E}[|\mathbf{1}\{V = k\} - \mathbf{1}\{W = k\}|] \\ &\leq \mathbb{E}[\mathbf{1}\{V \neq W\}] \\ &= \mathbb{P}(V \neq W). \end{aligned}$$

La cota (28) se deduce de observar que para todo  $k = 0, 1, \dots$

$$\begin{aligned} |\mathbb{P}(V = k) - \mathbb{P}(W = k)| &= |\mathbb{P}(V = k, W \neq k) - \mathbb{P}(W = k, V \neq k)| \\ &\leq \mathbb{P}(V = k, V \neq W) + \mathbb{P}(W = k, V \neq W), \end{aligned}$$

y luego sumar sobre los posibles valores de  $k$ :

$$\sum_k |\mathbb{P}(V = k) - \mathbb{P}(W = k)| \leq 2\mathbb{P}(V \neq W).$$

□

**Nota Bene.** Esta técnica, denominada técnica de acoplamiento de variables aleatorias, permite probar (sin usar la fórmula de Stirling) que la distribución Binomial converge a la distribución Poisson.

**Teorema 2.5** (Le Cam). Sean  $X_1, \dots, X_n$  variables aleatorias independientes con distribución Bernoulli de parámetros  $p_1, \dots, p_n$ , respectivamente y sea  $S = \sum_{i=1}^n X_i$ . Entonces

$$\sum_k |\mathbb{P}(S = k) - \mathbb{P}(N = k)| \leq 2 \sum_{i=1}^n p_i^2, \quad (29)$$

donde  $N$  es una variable aleatoria con distribución Poisson de media  $\lambda = \sum_{i=1}^n p_i$ .

**Demostración.** Sean  $U_1, \dots, U_n$  variables aleatorias independientes con distribución común  $\mathcal{U}[0, 1)$ . Construimos variables aleatorias acopladas  $V_i \sim \text{Bernoulli}(p_i)$  y  $W_i \sim \text{Poisson}(p_i)$ ,  $i = 1, \dots, n$ :

$$V_i := \mathbf{1}\{U_i \in I_1(p_i)\}, \quad W_i := \sum_{k=0}^{\infty} k \mathbf{1}\{U_i \in J_k(p_i)\},$$

y las sumamos

$$S^* = \sum_{i=1}^n V_i, \quad N = \sum_{i=1}^n W_i.$$

Por construcción, las variables  $V_1, \dots, V_n$  son independientes y con distribución Bernoulli( $p_i$ ), respectivamente, y entonces, la variable  $S^*$  tiene la misma distribución que  $S$ ; las variables  $W_1, \dots, W_n$  son independientes y tienen distribución Poisson( $p_i$ ), respectivamente, y entonces, la variable  $N$  tiene distribución Poisson de media  $\lambda = \sum_{i=1}^n p_i$ .

Observando que cada  $k$

$$|\mathbb{P}(S^* = k) - \mathbb{P}(N = k)| \leq \mathbb{P}(S^* = k, N \neq k) + \mathbb{P}(N = k, S^* \neq k).$$

se obtiene que

$$\sum_k |\mathbb{P}(S^* = k) - \mathbb{P}(N = k)| \leq 2\mathbb{P}(S^* \neq N).$$

Si  $S^* \neq N$ , entonces  $V_i \neq W_i$  para algún  $i = 1, \dots, n$ . En consecuencia,

$$\mathbb{P}(S^* \neq N) \leq \sum_{i=1}^n \mathbb{P}(V_i \neq W_i) \leq \sum_{i=1}^n p_i^2.$$

□

**Corolario 2.6** (Aproximación Poisson). *Para cada  $k \geq 0$*

$$\lim_{n \rightarrow \infty} \binom{n}{k} \left(1 - \frac{\lambda}{n}\right)^{n-k} \left(\frac{\lambda}{n}\right)^k = e^{-\lambda} \frac{\lambda^k}{k!}$$

**Demostación.** Sean  $U_1, \dots, U_n$  variables aleatorias independientes con distribución común  $\mathcal{U}[0, 1)$ . Para cada  $i = 1, \dots, n$  definimos parejas de variables aleatorias  $(V_i, W_i)$  independientes

$$V_i := \mathbf{1}\{U_i \in I_1(p)\}, \quad W_i := \sum_{k=0}^{\infty} k \mathbf{1}\{U_i \in J_k(p)\}.$$

Por construcción,  $V_i \sim \text{Bernoulli}(p)$  y  $W_i \sim \text{Poisson}(p)$ , en consecuencia las sumas

$$S = \sum_{i=1}^n V_i, \quad N = \sum_{i=1}^n W_i$$

son variables aleatorias con distribuciones Binomial( $n, p$ ) y Poisson( $np$ ), respectivamente. De acuerdo con la demostración del Teorema de Le Cam tenemos que

$$\left| \binom{n}{k} \left(1 - \frac{\lambda}{n}\right)^{n-k} \left(\frac{\lambda}{n}\right)^k - e^{-\lambda} \frac{\lambda^k}{k!} \right| = |\mathbb{P}(S = k) - \mathbb{P}(N = k)| \leq 2np^2 = 2\frac{\lambda^2}{n} \rightarrow 0.$$

□

**Teorema 2.7.** *Supongamos que para cada  $n$ ,  $X_{n,1}, \dots, X_{n,r_n}$  son variables aleatorias independientes con distribución Bernoulli( $p_{n,k}$ ). Si*

$$\sum_{k=1}^{r_n} p_{n,k} \rightarrow \lambda \geq 0, \quad \max_{1 \leq k \leq r_n} p_{n,k} \rightarrow 0, \quad (30)$$

entonces

$$\mathbb{P} \left( \sum_{k=1}^{r_n} X_{n,k} = i \right) \rightarrow e^{-\lambda} \frac{\lambda^i}{i!}, \quad i = 0, 1, 2, \dots \quad (31)$$

Si  $\lambda = 0$ , el límite (31) se interpreta como 1 para  $i = 0$  y 0 para  $i \geq 1$ . En el caso  $r_n = n$  y  $p_{n,k} = \lambda/n$ , (31) es la aproximación Poisson a la binomial. Notar que si  $\lambda > 0$ , entonces (30) implica que  $r_n \rightarrow \infty$ .

**Demostración.** Sean  $U_1, U_2, \dots$  variables aleatorias independientes, con distribución común  $\mathcal{U}[0, 1)$ . Definimos

$$V_{n,k} := \mathbf{1}\{U_k \in I_1(p_{n,k})\}.$$

Las variables  $V_{n,1}, \dots, V_{n,r_n}$  son independientes y con distribución Bernoulli( $p_{n,k}$ ). Puesto que  $V_{n,1}, \dots, V_{n,r_n}$  tienen la misma distribución que  $X_{n,1}, \dots, X_{n,r_n}$ , (31) se obtiene mostrando que  $V_n = \sum_{k=1}^{r_n} V_{n,k}$  satisface

$$\mathbb{P}(V_n = i) \rightarrow e^{-\lambda} \frac{\lambda^i}{i!}. \quad (32)$$

Ahora definimos

$$W_{n,k} := \sum_{i=0}^{\infty} i \mathbf{1}\{U_k \in J_i(p_{n,k})\}$$

$W_{n,k}$  tiene distribución Poisson de media  $p_{n,k}$ . Puesto que las  $W_{n,k}$  son independientes,  $W_n = \sum_{k=1}^{r_n} W_{n,k}$  tiene distribución Poisson de media  $\lambda_n = \sum_{k=1}^{r_n} p_{n,k}$ . De la desigualdad  $1 - p \leq e^{-p}$ , se obtiene como consecuencia que

$$\begin{aligned} \mathbb{P}(V_{n,k} \neq W_{n,k}) &= \mathbb{P}(V_{n,k} = 1 \neq W_{n,k}) = \mathbb{P}(U_k \in I_1(p_{n,k}) - J_1(p_{n,k})) \\ &= p_{n,k} - e^{-p_{n,k}} p_{n,k} \leq p_{n,k}^2, \end{aligned}$$

y por (30)

$$\mathbb{P}(V_n \neq W_n) \leq \sum_{k=1}^{r_n} p_{n,k}^2 \leq \lambda_n \max_{1 \leq k \leq r_n} p_{n,k} \rightarrow 0.$$

(32) y (31) se obtienen de observar que

$$\mathbb{P}(W_n = i) = e^{-\lambda_n} \frac{\lambda_n^i}{i!} \rightarrow e^{-\lambda} \frac{\lambda^i}{i!}.$$

□

## 3. Cuentas con exponenciales

### 3.1. Motivación: pasaje de lo discreto a lo continuo

Para fijar ideas consideraremos una conversación telefónica y supondremos que su duración es un número entero de segundos. La duración de la conversación será tratada como una variable aleatoria  $T$  cuya distribución de probabilidades  $p_n = \mathbb{P}(T = n)$  es conocida. La línea telefónica representa un sistema físico con dos estados posibles “ocupada” ( $E_0$ ) y “libre” ( $E_1$ ).

Imaginemos que cada segundo se decide si la conversación continúa o no por medio de una moneda cargada. En otras palabras, se realiza una sucesión de ensayos Bernoulli con

probabilidad de éxito  $p$  a una tasa de un ensayo por segundo y se continúa hasta el primer éxito. La conversación termina cuando ocurre el primer éxito. En este caso la duración total de la conversación, el *tiempo de espera*, tiene distribución geométrica  $p_n = (1 - p)^{n-1}p$ . Si en un instante cualquiera la línea está ocupada, la probabilidad que permanezca ocupada por más de un segundo es  $(1 - p)$ , y la probabilidad de transición  $E_0 \rightarrow E_1$  en el siguiente paso es  $p$ . En este caso esas probabilidades son independientes de cuánto tiempo estuvo ocupada la línea.

La descripción de los tiempos de espera mediante modelos discretos presupone la cuantización del tiempo y que los cambios solo pueden ocurrir en las épocas  $\varepsilon, 2\varepsilon, \dots$ . El tiempo de espera  $T$  más sencillo es el tiempo de espera hasta el primer éxito en una sucesión de ensayos Bernoulli con probabilidad de éxito  $p(\varepsilon)$ . En tal caso  $\mathbb{P}(T > n\varepsilon) = (1 - p(\varepsilon))^n$  y el tiempo medio de espera es  $\mathbb{E}[T] = \varepsilon/p(\varepsilon)$ . Este modelo puede ser refinado haciendo que  $\varepsilon$  sea cada vez más chico pero manteniendo fija la esperanza  $\varepsilon/p(\varepsilon) = 1/\lambda$ . Para un intervalo de duración  $t$  corresponden aproximadamente  $n \approx t/\varepsilon$  ensayos, y entonces para  $\varepsilon$  pequeño

$$\mathbb{P}(T > t) \approx (1 - \lambda\varepsilon)^{t/\varepsilon} \approx e^{-\lambda t}. \quad (33)$$

Este modelo considera el tiempo de espera como una variable aleatoria discreta distribuida geoméricamente y (33) dice que “en el límite” se obtiene una distribución exponencial.

Si no discretizamos el tiempo tenemos que tratar con variables aleatorias continuas. El rol de la distribución geométrica para los tiempos de espera lo ocupa la *distribución exponencial*. Es la *única variable continua dotada de una completa falta de memoria*. En otras palabras, la probabilidad de que una conversación que llegó hasta el tiempo  $t$  continúe más allá del tiempo  $t+s$  es independiente de la duración pasada de la conversación si, y solo si, la probabilidad que la conversación dure por lo menos  $t$  unidades de tiempo está dada por una exponencial  $e^{-\lambda t}$ .

**Nota Bene** Si en un momento arbitrario  $t$  la línea está ocupada, entonces la probabilidad de un cambio de estado durante el próximo segundo depende de cuán larga ha sido la conversación. En otras palabras, *el pasado influye sobre el futuro*. Esta circunstancia es la fuente de muchas dificultades en problemas más complicados.

### 3.2. Distribución exponencial

Se dice que la variable aleatoria  $T$  tiene *distribución exponencial de intensidad*  $\lambda > 0$  y se denota  $T \sim \text{Exp}(\lambda)$  si la función de distribución de  $T$  es de la forma

$$F(t) := \mathbb{P}(T \leq t) = (1 - e^{-\lambda t}) \mathbf{1}\{t \geq 0\}. \quad (34)$$

En tal caso  $T$  admite la siguiente función densidad de probabilidades

$$f(t) = \lambda e^{-\lambda t} \mathbf{1}\{t \geq 0\}. \quad (35)$$

De donde se deduce que los valores de la esperanza y la varianza de  $T$  son, respectivamente,  $\mathbb{E}[T] = 1/\lambda$  y  $\mathbb{V}(T) = 1/\lambda^2$ .

### 3.3. Suma de exponenciales independientes de igual intensidad

**Teorema 3.1.** Sean  $T_1, T_2, \dots, T_n$  variables aleatorias independientes, idénticamente distribuidas, con distribución exponencial de intensidad  $\lambda > 0$ . La suma  $S_n = T_1 + \dots + T_n$  admite una densidad de probabilidades de la forma

$$f_{S_n}(t) = \lambda e^{-\lambda t} \frac{(\lambda t)^{n-1}}{(n-1)!} \mathbf{1}\{t > 0\} \quad (36)$$

y su función de distribución es

$$F_{S_n}(t) = \left(1 - e^{-\lambda t} \sum_{i=0}^{n-1} \frac{(\lambda t)^i}{i!}\right) \mathbf{1}\{t \geq 0\}. \quad (37)$$

En otras palabras, la suma de  $n$  variables aleatorias independientes exponenciales de intensidad  $\lambda > 0$  tiene distribución Gamma de parámetros  $n$  y  $\lambda$ :  $\Gamma(n, \lambda)$ .

**Demostración.** Por inducción. Para  $n = 1$  no hay nada que probar:  $S_1 = T_1 \sim \text{Exp}(\lambda)$ . Supongamos ahora que la suma  $S_n = T_1 + \dots + T_n$  admite una densidad de la forma (36). Debido a que las variables aleatorias  $S_n$  y  $T_{n+1}$  son independientes, la densidad de  $S_{n+1} = S_n + T_{n+1}$  se obtiene convolucionando las densidades de  $S_n$  y  $T_{n+1}$ :

$$\begin{aligned} f_{S_{n+1}}(t) &= (f_{S_n} * f_{T_{n+1}})(t) \\ &= \int_0^t f_{S_n}(t-x) f_{T_{n+1}}(x) dx \\ &= \int_0^t \lambda e^{-\lambda(t-x)} \frac{(\lambda(t-x))^{n-1}}{(n-1)!} \lambda e^{-\lambda x} dx \\ &= \lambda e^{-\lambda t} \frac{\lambda^n}{(n-1)!} \int_0^t (t-x)^{n-1} dx \\ &= \lambda e^{-\lambda t} \frac{\lambda^n}{(n-1)!} \frac{t^n}{n} \\ &= \lambda e^{-\lambda t} \frac{(\lambda t)^n}{n!}. \end{aligned}$$

Las funciones de distribución (37) se obtienen integrando las densidades (36). Sea  $t \geq 0$ , integrando por partes puede verse que

$$\begin{aligned} F_{S_n}(t) &= \int_0^t f_{S_n}(s) ds \\ &= \int_0^t \frac{(\lambda s)^{n-1}}{(n-1)!} \lambda e^{-\lambda s} ds \\ &= -\frac{(\lambda s)^{n-1}}{(n-1)!} e^{-\lambda s} \Big|_0^t + \int_0^t \frac{(\lambda s)^{n-2}}{(n-2)!} \lambda e^{-\lambda s} ds \\ &= -\frac{(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t} + F_{S_{n-1}}(t). \end{aligned} \quad (38)$$

Iterando (38) obtenemos (37).  $\square$

**Nota Bene.** En la demostración anterior se utilizó el siguiente resultado: si  $T_1, \dots, T_n$  son variables aleatorias independientes, entonces funciones (medibles) de familias disjuntas de las  $T_i$  también son independientes. (Para más detalles ver el Capítulo 1 de Durrett, R., (1996). *Probability Theory and Examples*, Duxbury Press, New York.)  $\square$

### 3.4. Caracterización cualitativa de la distribución exponencial

Se dice que una variable aleatoria  $T$  no tiene memoria, o *pierde memoria*, si

$$\mathbb{P}(T > s + t | T > t) = \mathbb{P}(T > s) \quad \text{para todo } s, t \geq 0. \quad (39)$$

Si se piensa que  $T$  es el tiempo de vida de algún instrumento, la ecuación (39) establece que la probabilidad de que el instrumento viva al menos  $s + t$  horas dado que sobrevivió  $t$  horas es la misma que la probabilidad inicial de que viva al menos  $s$  horas.

La condición de pérdida de memoria es equivalente a la siguiente

$$\mathbb{P}(T > s + t) = \mathbb{P}(T > s)\mathbb{P}(T > t). \quad (40)$$

En efecto, basta observar que  $\mathbb{P}(T > s + t, T > t) = \mathbb{P}(T > s + t)$  y usar la definición de probabilidad condicional.

**Lema 3.2.** *La variable exponencial no tiene memoria.*

**Demostración** Si  $T \sim \text{Exp}(\lambda)$ , entonces

$$\mathbb{P}(T > t) = e^{-\lambda t} \quad \text{para todo } t \geq 0. \quad (41)$$

Usando (41) se prueba inmediatamente que la ecuación (40) se satisface cuando  $T$  tiene distribución exponencial (pues  $e^{-\lambda(s+t)} = e^{-\lambda s}e^{-\lambda t}$ ).  $\square$

**Ejemplo 3.3.** Supongamos que el tiempo de espera para recibir un mensaje tenga distribución exponencial de media 10 minutos. Cuál es la probabilidad de que tengamos que esperar más de 15 minutos para recibirlo? Cuál es la probabilidad de que tengamos que esperar más de 15 minutos para recibir el mensaje dado que hace más de 10 minutos que lo estamos esperando?

Si  $T$  representa el tiempo de espera,  $T \sim \text{Exp}(1/10)$ . La primer probabilidad es

$$\mathbb{P}(T > 15) = e^{-\frac{1}{10}15} = e^{-\frac{3}{2}} \approx 0.220$$

La segunda pregunta interroga por la probabilidad de que habiendo esperado 10 minutos tengamos que esperar al menos 5 minutos más. Usando la propiedad de falta de memoria de la exponencial, dicha probabilidad es

$$\mathbb{P}(T > 5) = e^{-\frac{1}{10}5} = e^{-\frac{1}{2}} \approx 0.604.$$

$\square$

La propiedad de pérdida de memoria caracteriza a la distribución exponencial.

**Teorema 3.4.** Sea  $T$  una variable aleatoria continua a valores en  $\mathbb{R}^+$ . Si  $T$  pierde memoria, entonces  $T \sim \text{Exp}(\lambda)$ , donde  $\lambda = -\log \mathbb{P}(T > 1)$ .

**Demostración (a la Cauchy).** Sea  $G(t) := \mathbb{P}(T > t)$ . De la ecuación (40) se deduce que

$$G(s+t) = G(s)G(t). \quad (42)$$

La única función continua a derecha que satisface la ecuación funcional (42) es

$$G(t) = G(1)^t. \quad (43)$$

Para ello basta ver que  $G\left(\frac{m}{n}\right) = G(1)^{\frac{m}{n}}$ . Si vale (42), entonces  $G\left(\frac{2}{n}\right) = G\left(\frac{1}{n} + \frac{1}{n}\right) = G\left(\frac{1}{n}\right)G\left(\frac{1}{n}\right) = G\left(\frac{1}{n}\right)^2$  y repitiendo el argumento se puede ver que

$$G\left(\frac{m}{n}\right) = G\left(\frac{1}{n}\right)^m. \quad (44)$$

En particular, si  $m = n$  se obtiene  $G(1) = G\left(\frac{1}{n}\right)^n$ . Equivalentemente,

$$G\left(\frac{1}{n}\right) = G(1)^{\frac{1}{n}}. \quad (45)$$

De las identidades (44) y (45) se deduce que

$$G\left(\frac{m}{n}\right) = G(1)^{\frac{m}{n}}. \quad (46)$$

Ahora bien, debido a que  $G(1) = \mathbb{P}(T > 1) \in (0, 1)$ , existe  $\lambda > 0$  tal que  $G(1) = e^{-\lambda}$  ( $\lambda = -\log G(1)$ ). Reemplazando en (43) se obtiene  $G(t) = (e^{-\lambda})^t = e^{-\lambda t}$ .  $\square$

### 3.5. Mínimos

**Lema 3.5.** Sean  $T_1$  y  $T_2$  dos variables aleatorias independientes y exponenciales de intensidades  $\lambda_1$  y  $\lambda_2$ , respectivamente. Vale que

$$\mathbb{P}(T_1 < T_2) = \frac{\lambda_1}{\lambda_1 + \lambda_2}. \quad (47)$$

**Demostración.** La probabilidad  $\mathbb{P}(T_1 < T_2)$  puede calcularse condicionando sobre  $T_1$ :

$$\begin{aligned} \mathbb{P}(T_1 < T_2) &= \int_0^\infty \mathbb{P}(T_1 < T_2 | T_1 = t) f_{T_1}(t) dt = \int_0^\infty \mathbb{P}(t < T_2) \lambda_1 e^{-\lambda_1 t} dt \\ &= \lambda_1 \int_0^\infty e^{-\lambda_2 t} e^{-\lambda_1 t} dt = \lambda_1 \int_0^\infty e^{-(\lambda_1 + \lambda_2)t} dt = \frac{\lambda_1}{\lambda_1 + \lambda_2}. \end{aligned}$$

$\square$



**Teorema 3.6.** Sean  $T_1, T_2, \dots, T_n$  variables aleatorias exponenciales independientes de intensidades  $\lambda_1, \lambda_2, \dots, \lambda_n$ , respectivamente. Sean  $T$  y  $J$  las variables aleatorias definidas por

$$T := \min_i T_i, \quad J := \text{índice que realiza } T.$$

Entonces,  $T$  tiene distribución exponencial de intensidad  $\lambda_1 + \dots + \lambda_n$  y

$$\mathbb{P}(J = j) = \frac{\lambda_j}{\lambda_1 + \dots + \lambda_n}.$$

Más aún, las variables  $T$  y  $J$  son independientes.

**Demostración.** En primer lugar, hay que observar que  $T > t$  si y solo si  $T_i > t$  para todo  $i = 1, \dots, n$ . Como las variables  $T_1, T_2, \dots, T_n$  son exponenciales independientes de intensidades  $\lambda_1, \lambda_2, \dots, \lambda_n$  tenemos que

$$\mathbb{P}(T > t) = \prod_{i=1}^n \mathbb{P}(T_i > t) = \prod_{i=1}^n e^{-\lambda_i t} = e^{-(\lambda_1 + \dots + \lambda_n)t}.$$

Por lo tanto,  $T$  tiene distribución exponencial de intensidad  $\lambda_1 + \dots + \lambda_n$ .

En segundo lugar hay que observar que  $J = j$  si y solo si  $T = T_j$ . Por lo tanto,

$$\mathbb{P}(J = j) = \mathbb{P}(T_j = \min_i T_i) = \mathbb{P}(T_j < \min_{i \neq j} T_i) = \frac{\lambda_j}{\lambda_1 + \dots + \lambda_n}.$$

La última igualdad se obtiene utilizando el Lema 3.5 pues las variables  $T_j$  y  $\min_{i \neq j} T_i$  son independientes y exponenciales con intensidades  $\lambda_j$  y  $\sum_{i \neq j} \lambda_i$ , respectivamente.

Finalmente, si para cada  $j$  definimos  $U_j = \min_{i \neq j} T_i$ , tenemos que

$$\begin{aligned} \mathbb{P}(J = j, T \geq t) &= \mathbb{P}(t \leq T_j < U_j) = \int_t^\infty \mathbb{P}(T_j < U_j | T_j = s) \lambda_j e^{-\lambda_j s} ds \\ &= \lambda_j \int_t^\infty \mathbb{P}(U_j > s) e^{-\lambda_j s} ds \\ &= \lambda_j \int_t^\infty e^{-(\sum_{i \neq j} \lambda_i)s} e^{-\lambda_j s} ds \\ &= \frac{\lambda_j}{\lambda_1 + \dots + \lambda_n} \int_t^\infty (\lambda_1 + \dots + \lambda_n) e^{-(\lambda_1 + \dots + \lambda_n)s} ds \\ &= \frac{\lambda_j}{\lambda_1 + \dots + \lambda_n} e^{-(\lambda_1 + \dots + \lambda_n)t}. \end{aligned}$$

Lo que completa la demostración. □

## Ejercicios adicionales

7. Sean  $T_1$  y  $T_2$  variables aleatorias independientes exponenciales de parámetro 2. Sean  $T_{(1)} = \min(T_1, T_2)$  y  $T_{(2)} = \max(T_1, T_2)$ . Hallar la esperanza y la varianza de  $T_{(1)}$  y de  $T_{(2)}$ .
8. Una lámpara tiene una vida, en horas, con distribución exponencial de parámetro 1. Un jugador enciende la lámpara y, mientras la lámpara está encendida, lanza un dado equilibrado de quince en quince segundos. Hallar el número esperado de 3's observados hasta que la lámpara se apague.
9. *Suma geométrica de exponenciales independientes.* Sean  $T_1, T_2, \dots$  variables aleatorias independientes idénticamente distribuidas con ley exponencial de intensidad  $\lambda = 2$ . Se define  $T = \sum_{i=1}^N T_i$ , donde  $N$  es una variable aleatoria con distribución geométrica de parámetro  $p = 1/3$ , independiente de las variables  $T_1, T_2, \dots$ . Hallar la distribución de  $T$ . (*Sugerencia:* Utilizar la fórmula de probabilidad total condicionando a los posibles valores de  $N$  y el desarrollo en serie de Taylor de la función exponencial.)
- 

## 4. Bibliografía consultada

Para redactar estas notas se consultaron los siguientes libros:

1. Billingsley, P.: Probability and measure. John Wiley & Sons, New York. (1986)
2. Durrett R.: Probability. Theory and Examples. Duxbury Press, Belmont. (1996)
3. Feller, W.: An introduction to Probability Theory and Its Applications. Vol. 1. John Wiley & Sons, New York. (1957)
4. Feller, W.: An introduction to Probability Theory and Its Applications. Vol. 2. John Wiley & Sons, New York. (1971)
5. Grimmett, G. R., Stirzaker, D. R.: Probability and Random Processes. Oxford University Press, New York. (2001)
6. Meester, R.: A Natural Introduction to Probability Theory. Birkhauser, Berlin. (2008).
7. Meyer, P. L.: Introductory Probability and Statistical Applications. Addison-Wesley, Massachusetts. (1972)
8. Ross, S. M: Introduction to Probability and Statistics for Engineers and Scientists. Elsevier Academic Press, San Diego. (2004)
9. Soong, T. T.: Fundamentals of Probability and Statistics for Engineers. John Wiley & Sons Ltd. (2004)