

Repaso de Probabilidad

Germán Capdehourat, Sergio Martínez, Pablo Musé
{gcapde, sematag, pmuse}@fing.edu.uy

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

3 de agosto de 2021

Sigma-álgebras y espacios de probabilidad

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

- ▶ Un suceso es algo que ocurre
- ▶ Todo suceso aleatorio tiene un resultado incierto
 - ⇒ La probabilidad de un suceso **mide** cuán verosímil es que este ocurra

Ejemplo

- ▶ Escribo el número de cédula de identidad de un estudiante en un papel. Quién es?
- ▶ **Suceso:** La C.I. del estudiante x está escrita en el papel
- ▶ **Probabilidad:** $P(x)$ mide cuán verosímil es que el número de C.I. de x esté escrito
- ▶ **La probabilidad es un instrumento de medida**
 - ⇒ Lenguaje matemático para cuantificar la incertidumbre

- ▶ Dado un **espacio muestral** or universo Ω (también **espacio de sucesos elementales**)
 - ▶ Ej: Todos los estudiantes del curso, $\Omega = \{x_1, x_2, \dots, x_N\}$ (x_n representa número de C.I.)
- ▶ **Def:** Un **suceso elemental** es un elemento o punto de Ω , e.g., x_3
- ▶ **Def:** Un **suceso E es un subconjunto de Ω**
 - ▶ Ej: $\{x_1\}$, estudiante con número de C.I. x_1
 - ▶ Ej: $\{x_1, x_4\}$, estudiantes con número de C.I. x_1 o x_4

\Rightarrow Suceso elemental x_3 y suceso $\{x_3\}$ **son cosas distintas**, éste último es un conjunto
- ▶ **Def:** Una **sigma-álgebra \mathcal{F}** es un conjunto de sucesos $E \subseteq \Omega$ tal que
 - El conjunto vacío (*suceso imposible*) \emptyset pertenece a \mathcal{F} : $\emptyset \in \mathcal{F}$
 - Es cerrado por **complemento**: Si $E \in \mathcal{F}$, entonces $E^c \in \mathcal{F}$
 - Es cerrado por **unión numerable**: Si $E_1, E_2, \dots \in \mathcal{F}$, entonces $\bigcup_{i=1}^{\infty} E_i \in \mathcal{F}$
- ▶ \mathcal{F} es un conjunto de conjuntos

Ejemplos de sigma-álgebras

Ejemplo

- ▶ Ningún estudiante y todos los estudiantes, i.e., $\mathcal{F}_0 := \{\emptyset, \Omega\}$

Ejemplo

- ▶ Conjunto vacío, mujeres, hombres, todos, i.e.,
 $\mathcal{F}_1 := \{\emptyset, \text{Mujeres}, \text{Hombres}, \Omega\}$

Ejemplo

- ▶ \mathcal{F}_2 incluyendo el conjunto vacío \emptyset **más**
todos los sucesos (conjuntos) con un estudiante $\{x_1\}, \dots, \{x_N\}$ **más**
todos los sucesos con dos estudiantes $\{x_1, x_2\}, \{x_1, x_3\}, \dots, \{x_1, x_N\},$
 $\{x_2, x_3\}, \dots, \{x_2, x_N\},$
 \dots
 $\{x_{N-1}, x_N\}$ **más**
todos los sucesos con tres, cuatro, \dots , N estudiantes
 $\Rightarrow \mathcal{F}_2$ se conoce como **conjunto potencia** o **conjunto de las partes**
de Ω , y se escribe 2^Ω ($|2^\Omega| = 2^{|\Omega|}$)

Axiomas de la teoría de la probabilidad

- ▶ Sea una función $P(E)$ de una sigma-álgebra \mathcal{F} a los números reales
- ▶ $P(E)$ es una probabilidad si
 - A1) **Non-negatividad**: $P(E) \geq 0$
 - A2) **Probabilidad del universo**: $P(\Omega) = 1$
 - A3) **Aditividad**: Dada un sucesión de sucesos **disjuntos** E_1, E_2, \dots

$$P\left(\bigcup_{i=1}^{\infty} E_i\right) = \sum_{i=1}^{\infty} P(E_i)$$

⇒ Sucesos disjuntos (o incompatibles dos a dos) significa $E_i \cap E_j = \emptyset, i \neq j$

⇒ **Unión de infinitos sucesos disjuntos numerables**

- ▶ La terna (Ω, \mathcal{F}, P) se llama **espacio de probabilidad**

► Implicancias de los axiomas A1)-A3)

⇒ **Suceso imposible:** $P(\emptyset) = 0$

⇒ **Monotonía:** $E_1 \subset E_2 \Rightarrow P(E_1) \leq P(E_2)$

⇒ **Imagen:** $0 \leq P(E) \leq 1$

⇒ **Complemento:** $P(E^c) = 1 - P(E)$

⇒ **Union disjunta finita:** Para sucesos disjuntos E_1, \dots, E_N

$$P\left(\bigcup_{i=1}^N E_i\right) = \sum_{i=1}^N P(E_i)$$

⇒ **Inclusión-exclusión:** Para **cualquier** par de sucesos E_1 and E_2

$$P(E_1 \cup E_2) = P(E_1) + P(E_2) - P(E_1 \cap E_2)$$

Ejemplo de espacio de probabilidad

- ▶ Construyamos un **espacio de probabilidad** para nuestro ejemplo
- ▶ Universo de todos los estudiantes del curso $\Omega = \{x_1, x_2, \dots, x_N\}$
- ▶ Sigma-álgebra con todas las combinaciones de estudiantes, i.e., $\mathcal{F} = 2^\Omega$
- ▶ Los números de C.I. escritos son equiprobables $\Rightarrow P(\{x_n\}) = 1/N$,
 $n = 1, \dots, N$
 \Rightarrow **Especifiquemos la probabilidad para todo $E \in \mathcal{F}$** \Rightarrow definimos
$$P(E) = \frac{|E|}{|\Omega|}$$
- ▶ **Q:** Es esta función una probabilidad?
 \Rightarrow **A1):** $P(E) = \frac{|E|}{|\Omega|} \geq 0 \checkmark$ \Rightarrow **A2):** $P(\Omega) = \frac{|\Omega|}{|\Omega|} = 1 \checkmark$
 \Rightarrow **A3):** $P\left(\bigcup_{i=1}^N E_i\right) = \frac{|\bigcup_{i=1}^N E_i|}{|\Omega|} = \frac{\sum_{i=1}^N |E_i|}{|\Omega|} = \sum_{i=1}^N P(E_i) \checkmark$
- ▶ La función $P(\cdot)$ así definida se llama **distribución uniforme**

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas


Probabilidad condicional

- ▶ Consideremos los sucesos E y F , y **supongamos que sabemos que F ha ocurrido**
- ▶ **Q:** Qué información nos da esto sobre la probabilidad de E ?
- ▶ **Def:** La **probabilidad condicional de E dado F** es (necesitamos que $P(F) > 0$)

$$P(E|F) = \frac{P(E \cap F)}{P(F)}$$

⇒ En general $P(E|F) \neq P(F|E)$

- ▶ **Renormalizamos** las probabilidades al conjunto F
 - ▶ Descartamos una parte de Ω
 - ▶ Eventualmente también puede descartarse una parte de E



- ▶ Dado F con $P(F) > 0$, $P(\cdot|F)$ satisface los axiomas de la probabilidad

Ejemplo de probabilidad condicional

- ▶ El nombre de C.I. escrito corresponde a un estudiante de sexo masculino. Cuál es la probabilidad de x_n ?
- ▶ Supongamos que los hombres son $F = \{x_1, \dots, x_M\} \Rightarrow P(F) = \frac{M}{N}$
- ▶ Si el número de C.I. x_n es de un **hombre**, $x_n \in F$ y tenemos el suceso $E = \{x_n\}$

$$P(E \cap F) = P(\{x_n\}) = \frac{1}{N}$$

\Rightarrow La probabilidad condicional es, como esperamos

$$P(E | F) = \frac{P(E \cap F)}{P(F)} = \frac{1/N}{M/N} = \frac{1}{M}$$

- ▶ Si el número de C.I. es de una **mujer** $x_n \notin F$, entonces $P(E \cap F) = P(\emptyset) = 0$
 \Rightarrow Tenemos entonces $P(E | F) = 0$

Ley de la probabilidad total

- ▶ Consideremos el suceso E y los sucesos F y F^c
 - ▶ F y F^c forman una **partición** de Ω ($F \cup F^c = S$, $F \cap F^c = \emptyset$)
- ▶ Como $F \cup F^c = \Omega$ cubre Ω , podemos escribir el conjunto E como

$$E = E \cap S = E \cap [F \cup F^c] = [E \cap F] \cup [E \cap F^c]$$


- ▶ Como $F \cap F^c = \emptyset$ son **disjuntos**, también lo son
 $[E \cap F] \cap [E \cap F^c] = \emptyset$
 - $\Rightarrow P(E) = P([E \cap F] \cup [E \cap F^c]) = P(E \cap F) + P(E \cap F^c)$
- ▶ Usando la definición de probabilidad condicional

$$P(E) = P(E | F)P(F) + P(E | F^c)P(F^c)$$

- ▶ Esto traduce la información **condicional** $P(E | F)$ y $P(E | F^c)$
 - \Rightarrow En información **incondicional** $P(E)$

Ley de la probabilidad total (cont.)

- ▶ En general, sea la **partición** de Ω (posiblemente infinita), $F_i, i = 1, 2, \dots$
- ▶ Los conjuntos son **disjuntos**
 $\Rightarrow F_i \cap F_j = \emptyset$ para $i \neq j$
- ▶ Los conjuntos **cubren el espacio**
 $\Rightarrow \bigcup_{i=1}^{\infty} F_i = \Omega$



- ▶ Igual que antes, como $\bigcup_{i=1}^{\infty} F_i = \Omega$ **cubre el espacio**, podemos escribir E como

$$E = E \cap \Omega = E \cap \left[\bigcup_{i=1}^{\infty} F_i \right] = \bigcup_{i=1}^{\infty} [E \cap F_i]$$

- ▶ Como $F_i \cap F_j = \emptyset$ son **disjuntos**, también $[E \cap F_i] \cap [E \cap F_j] = \emptyset$.
Luego

$$P(E) = P\left(\bigcup_{i=1}^{\infty} [E \cap F_i]\right) = \sum_{i=1}^{\infty} P(E \cap F_i) = \sum_{i=1}^{\infty} P(E | F_i) P(F_i)$$

Ejemplo de probabilidad total

- ▶ Consideremos un curso de probabilidad en alguna universidad
 - ⇒ Los estudiantes avanzados aprueban con A con probabilidad 0.9, los principiantes con probabilidad 0.8
 - ⇒ Un estudiante de intercambio es avanzado con probabilidad 0.7, y principiante con probabilidad 0.3
- ▶ **Q:** ¿Cuál es la probabilidad de que el estudiante de intercambio apruebe con A?
- ▶ Sea E = “el estudiante de intercambio aprueba con A”, a por avanzado, p por principiante
 - ⇒ Usamos la **ley de la probabilidad total**

$$\begin{aligned}P(E) &= P(E | a)P(a) + P(E | p)P(p) \\ &= 0,9 \times 0,7 + 0,8 \times 0,3 = 0,87\end{aligned}$$

- ▶ De la definición de probabilidad condicional: $P(E | F)P(F) = P(E \cap F)$
- ▶ De la misma forma: $P(F | E)P(E) = P(F \cap E)$
- ▶ Como ambas cantidades son iguales, obtenemos la **regla de Bayes**

$$P(E | F) = \frac{P(F | E)P(E)}{P(F)}$$

- ▶ La regla de Bayes permite la **inversión temporal** o de causalidad. Si F (futuro) viene después de E (pasado),
 - $\Rightarrow P(E | F)$, prob. que el pasado (E) haya visto el futuro (F)
 - $\Rightarrow P(F | E)$, proba. que el futuro (F) corresponda al pasado (E)
- ▶ En general los modelos describen **futuro | pasado** (modelo directo). Usualmente interesa **pasado | futuro** (modelo inverso).

Ejemplo de regla de Bayes

- ▶ Consideremos la siguiente partición de mis emails
 - ⇒ E_1 = “spam” con probabilidad $P(E_1) = 0,7$
 - ⇒ E_2 = “baja prioridad” con probabilidad $P(E_2) = 0,2$
 - ⇒ E_3 = “alta prioridad” con probabilidad $P(E_3) = 0,1$
- ▶ Sea el suceso F = “el email contiene la palabra *gratis*”
 - ⇒ De la experiencia previa sabemos que $P(F | E_1) = 0,9$,
 $P(F | E_2) = P(F | E_3) = 0,01$
- ▶ Recibo un email con la palabra “gratis”. ¿Cuál es la probabilidad que sea spam?
- ▶ Aplicamos la **regla de Bayes**

$$P(E_1 | F) = \frac{P(F | E_1)P(E_1)}{P(F)} = \frac{P(F | E_1)P(E_1)}{\sum_{i=1}^3 P(F | E_i)P(E_i)} = 0,995$$

⇒ **Ley de la probabilidad total**: muy útil cuando se aplica la regla de Bayes

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

- ▶ **Def:** los sucesos E y F son **independientes** si $P(E \cap F) = P(E)P(F)$
 - ⇒ Sucesos que no son independientes son **dependientes**
- ▶ $P(E | F) = \frac{P(E \cap F)}{P(F)} = \frac{P(E)P(F)}{P(F)} = P(E)$
 - ⇒ Intuitivamente, **conocer F no altera nuestra percepción sobre E**
 - ⇒ **F no contiene información sobre E**
 - ⇒ El recíproco también es cierto: $P(F | E) = P(F)$
- ▶ El que E y F sean independientes depende fuertemente de $P(\cdot)$
- ▶ **Atención:** evitar confundir sucesos independientes con sucesos disjuntos, i.e. $E \cap F = \emptyset$
- ▶ **Q:** ¿Dos sucesos disjuntos con probabilidades $P(E) > 0$, $P(F) > 0$ pueden ser independientes? **No** → **Eventos disjuntos posibles son necesariamente dependientes**
- ▶ Ej. 1: bolillero con los números $\{1, 2, 3, 4\}$. Saco una bolilla B . Los eventos " B es par" y " $B \leq 2$ " son independientes, pero no son disjuntos.
- ▶ Ej. 2: Ω universo, $E \subset \Omega$ evento. $P(\Omega \cap E) = P(E) = P(E)P(\Omega)$.

Ejemplo de independencia

- ▶ Escribo un número de C.I. de los estudiantes del curso, y le pido a un amigo que escriba otro (puede ser mismo)
- ▶ Espacio de probabilidad para el experimento: $(S, \mathcal{F}, P(\cdot))$
 - ⇒ S es el conjunto de todos los pares de números de C.I. de los estudiantes: $[x_n(1), x_n(2)]$, $|\Omega| = N^2$
 - ⇒ La sigma-álgebra es el producto cartesiano $\mathcal{F} = 2^\Omega \times 2^\Omega$
 - ⇒ Definimos $P(E) = \frac{|E|}{|\Omega|}$ como la ley uniforme
- ▶ Consideramos los sucesos $E_1 = \text{'Yo escribí } x_1 \text{'}$ y $E_2 = \text{'Mi amigo escribió } x_2 \text{'}$ Q: ¿Son **independientes**? Sí, ya que

$$P(E_1 \cap E_2) = P(\{(x_1, x_2)\}) = \frac{|\{(x_1, x_2)\}|}{|\Omega|} = \frac{1}{N^2} = P(E_1)P(E_2)$$

- ▶ Sucesos **dependientes**: $E_1 = \text{'Yo escribí } x_1 \text{'}$ y $E_3 = \text{'Ambos estudiantes son hombres'}$

Independencia para más de dos sucesos

- ▶ **Def:** Los sucesos E_i , $i = 1, 2, \dots$ se dicen **mutuamente independientes** si

$$P\left(\bigcap_{i \in I} E_i\right) = \prod_{i \in I} P(E_i)$$

para **todo subconjunto finito** I de al menos dos enteros

- ▶ **Ej:** los sucesos E_1 , E_2 , y E_3 son mutuamente independientes si se cumple que

$$P(E_1 \cap E_2 \cap E_3) = P(E_1)P(E_2)P(E_3)$$

$$P(E_1 \cap E_2) = P(E_1)P(E_2)$$

$$P(E_1 \cap E_3) = P(E_1)P(E_3)$$

$$P(E_2 \cap E_3) = P(E_2)P(E_3)$$

- ▶ Si $P(E_i \cap E_j) = P(E_i)P(E_j)$ para todo (i, j) , los E_i son **independent dos a dos**
⇒ Independencia mutua → independencia dos a dos. **No recíprocamente**

Variables aleatorias

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

Definición de variable aleatorias (VA)

- ▶ **Def:** Una VA $X(\omega)$ es una **función** que le asigna un valor a un suceso elemental $\omega \in \Omega$
 - ⇒ Podemos pensar en VAs como medidas asociadas a un experimento

Ejemplo

- ▶ Tiramos una pelota en un cuadrado de $1m \times 1m$. Nos interesa la posición de la pelota
- ▶ Una **realización incierta** es el lugar ω donde cae la pelota
- ▶ Las **variables aleatorias** son $X(\omega)$ e $Y(\omega)$, coordenadas espaciales
- ▶ Las probabilidades de las VAs se infieren de los sucesos elementales subyacentes

$$P(X(\omega) = x) = P(\{\omega \in \Omega : X(\omega) = x\})$$

$$P(X(\omega) \in (-\infty, x]) = P(\{\omega \in \Omega : X(\omega) \in (-\infty, x]\})$$

Ejemplo 1

- ▶ Se tira una moneda, cara (H) o cruz (T). La moneda no está cargada $P(H) = 1/2$, $P(T) = 1/2$. Se paga \$1 por H , se cobra \$1 por T . **Ganancia?**
- ▶ Las realizaciones posibles son H y T
- ▶ Para medir la ganancia se define la VA X con valores

$$X(H) = 1, \quad X(T) = -1$$

- ▶ Las probabilidades de la VA son

$$\begin{aligned}P(X = 1) &= P(H) = 1/2, \\P(X = -1) &= P(T) = 1/2\end{aligned}$$

⇒ Se tiene $P(X = x) = 0$ para todo $x \neq \pm 1$

Ejemplo 2

- ▶ Se tiran 2 monedas. Se paga \$1 por cada H , se cobra \$1 por cada T . **Ganancia?**
- ▶ Ahora las realizaciones posibles son HH , HT , TH , and TT
- ▶ Para medir la ganancia se define la VA Y con valores

$$Y(HH) = 2, \quad Y(HT) = 0, \quad Y(TH) = 0, \quad Y(TT) = -2$$

- ▶ Las probabilidades par la VA son

$$P(Y = 2) = P(HH) = 1/4,$$

$$P(Y = 0) = P(HT) + P(TH) = 1/2,$$

$$P(Y = -2) = P(TT) = 1/4$$

Sobre los ejemplos 1 y 2

- ▶ Las VAs son más fáciles de manejar que los sucesos
- ▶ Sea $\omega_1 \in \{H, T\}$ una realización de la moneda 1 y $\omega_2 \in \{H, T\}$ de la moneda 2
⇒ Se puede vincular Y y X como

$$Y(\omega_1, \omega_2) = X_1(\omega_1) + X_2(\omega_2)$$

- ▶ Se tiran N monedas. **Ganancia?** La enumeración se vuelve engorrosa
- ▶ Alternativamente, sea $\omega_n \in \{H, T\}$ la realización de la n -ésima tirada. Se define

$$Y(\omega_1, \omega_2, \dots, \omega_N) = \sum_{n=1}^N X_n(\omega_n)$$

⇒ En general se utiliza el abuso de notación $Y = \sum_{n=1}^N X_n$

Ejemplo 3

- ▶ Se tira una moneda hasta que sale H por primera vez. $P(H) = p$
- ▶ ¿Cuántas tiradas se hacen hasta que sale la primera H?
- ▶ Las realizaciones posibles son $H, TH, TTH, TTTH, \dots$ Obs:
 $|S| = \infty$
 - ⇒ Se deja de tirar luego de obtener la primera H (e.g. THT no es una realización posible)
- ▶ Sea N la VA que cuenta la **cantidad de tiradas**
 - ⇒ $N = n$ si sale T en las primeras $n - 1$ tiradas, y H en la n -ésima

$$P(N = 1) = P(H) = p$$

$$P(N = 2) = P(TH) = (1 - p)p$$

⋮

$$P(N = n) = P(\underbrace{TT \dots T}_{n-1 \text{ veces}} H) = (1 - p)^{n-1} p$$

Example 3 (continued)

- ▶ De A2) deberíamos tener $P(S) = \sum_{n=1}^{\infty} P(N=n) = 1$
- ▶ Cierto porque $\sum_{n=1}^{\infty} (1-p)^{n-1}$ es una **serie geométrica**

$$\sum_{n=1}^{\infty} (1-p)^{n-1} = 1 + (1-p) + (1-p)^2 + \dots = \frac{1}{1-(1-p)} = \frac{1}{p}$$

- ▶ Sustituyendo la suma de la serie geométrica en la expresión de $P(S)$

$$\sum_{n=1}^{\infty} P(N=n) = p \sum_{n=1}^{\infty} (1-p)^{n-1} = p \times \frac{1}{p} = 1 \checkmark$$

Función indicatriz

- ▶ La **función indicatriz de un suceso** es una VA
- ▶ Sea $\omega \in \Omega$ una realización, y $E \subset \Omega$ un suceso

$$\mathbb{I}\{E\}(\omega) = \begin{cases} 1, & \text{if } \omega \in E \\ 0, & \text{if } \omega \notin E \end{cases}$$

⇒ Indica que la realización ω pertenece al conjunto E , tomando el valor 1

Ejemplo

- ▶ Cantidad N de tiradas de monedas hasta la primera H . Nos interesa cuándo N supera N_0
 - ⇒ El suceso es $\{N : N > N_0\}$. Las realizaciones posibles son $N = 1, 2, \dots$
 - ⇒ Llamamos a la función indicatriz $\mathbb{I}_{N_0} = \mathbb{I}\{N : N > N_0\}$
- ▶ La probabilidad $P(\mathbb{I}_{N_0} = 1) = P(N > N_0) = (1 - p)^{N_0}$
 - ⇒ Para que N supere N_0 se necesitan N_0 consecutivas T
 - ⇒ **No importa lo que suceda luego**

Variables aleatorias discretas

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas



Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

- ▶ Las **VA discretas** toman, a lo sumo, un conjunto **numerable** de valores
- ▶ **Función de (masa de) probabilidad** o **probability mass function (pmf)** $p_X(x) = P(X = x)$
 - ▶ Si la VA es clara del contexto, simplemente escribimos $p_X(x) = p(x)$
- ▶ Si X tiene soporte $\{x_1, x_2, \dots\}$, su **pmf** satisface
 - $p(x_i) > 0$ for $i = 1, 2, \dots$
 - $p(x) = 0$ for all other $x \neq x_i$
 - $\sum_{i=1}^{\infty} p(x_i) = 1$
 - ▶ pmf para “cantidad de tiradas hasta primera cara” ($p = 0,3$)
- ▶ **Función de distribución (acumulada) (cdf)**
 $F_X(x) = P(X \leq x) = \sum_{i: x_i \leq x} p(x_i)$
 - \Rightarrow **Función creciente con saltos en x_i**
 - ▶ cdf para “cantidad de tiradas hasta la primer cara” (con $p = 0,3$)




Distribución de Bernoulli


- ▶ Un experimento es exitoso con probabilidad p or fallido con probabilidad $q := 1 - p$
 - ⇒ Ex: Tirar una moneda, cualquier indicatriz de un suceso
- ▶ Bernoulli X toma valores 0 o 1. Su pmf es $p(x) = p^x q^{1-x}$
- ▶ Su cdf es

$$F(x) = \begin{cases} 0, & x < 0 \\ q, & 0 \leq x < 1 \\ 1, & x \geq 1 \end{cases}$$

pmf ($p = 0,4$)





cdf ($p = 0,4$)



Distribución geométrica

- ▶ Cuenta la cantidad de experimentos de Bernoulli hasta registrar el primer éxito
 - ⇒ Cada experimento tiene éxito con probabilidad p
- ▶ La cantidad de experimentos hasta éxito, X , sigue una distribución geométrica con parámetro p
- ▶ pmf: $p(x) = p(1 - p)^{x-1}$
 - ▶ Un éxito luego de $x - 1$ fallas. Los experimentos (las VAs de Bernoulli) son independientes
- ▶ cdf: $F(x) = 1 - (1 - p)^x$
 - ▶ Recordar que $P(X > x) = (1 - p)^x$; sino sumar la serie geométrica



Distribución binomial


- ▶ Cuenta la cantidad de éxitos entre n experimentos de Bernoulli
 - ⇒ Cada experimento tiene éxito con probabilidad p
- ▶ La cantidad de éxitos X sigue una distribución **binomial** con **parámetros** (n, p) . Su pmf es

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


⇒ $X = x$ for x éxitos (p^x) and $n - x$ fallas ($(1-p)^{n-x}$).

⇒ $\binom{n}{x}$ formas de escoger x éxitos entre n experimentos

pmf ($n = 9, p = 0,4$)



cdf ($n = 9, p = 0,4$)



Distribución binomial (cont.)

- ▶ Sean $Y_i, i = 1, \dots, n$ VAs de Bernoulli con parámetro p
 - ⇒ Las Y_i están asociadas a sucesos independientes
- ▶ Podemos escribir la binomial X como la con parámetros (n, p) como

$$\Rightarrow X = \sum_{i=1}^n Y_i$$

Ejemplo

- ▶ Considere las binomiales Y and Z con parámetros (n_Y, p) y (n_Z, p)
 - ⇒ **Q:** ¿Distribución de probabilidad de $X = Y + Z$?
- ▶ Escribimos $Y = \sum_{i=1}^{n_Y} Y_i$ and $Z = \sum_{i=1}^{n_Z} Z_i$, luego

$$X = \sum_{i=1}^{n_Y} Y_i + \sum_{i=1}^{n_Z} Z_i$$

⇒ X binomial con parámetro $(n_Y + n_Z, p)$

Distribución de Poisson


- ▶ Cuenta eventos raros (decay radioactivo, arribo paquetes, accidentes)
- ▶ Usualmente se modela como Poisson con parámetro λ y pmf

$$p(x) = e^{-\lambda} \frac{\lambda^x}{x!}$$


- ▶ Q: ¿La pmf está bien definida? Sí
- ▶ Desarrollo de Taylor de $e^x = 1 + x + x^2/2 + \dots + x^i/i! + \dots$

$$\text{Entonces } P(\Omega) = \sum_{i=0}^{\infty} p(i) = e^{-\lambda} \sum_{i=0}^{\infty} \frac{\lambda^i}{i!} = e^{-\lambda} e^{\lambda} = 1 \checkmark$$

pmf ($\lambda = 4$)




cdf ($\lambda = 4$)



Aproximación de la binomial como Poisson

- ▶ X binomial con parámetros (n, p)
- ▶ Sea $n \rightarrow \infty$ manteniendo el producto $np = \lambda$ constante
 - ▶ (Si solo hacemos $n \rightarrow \infty$ la cantidad de éxitos diverge).
- ▶ Comparemos con la distribución de Poisson de parámetro λ
 - ▶ $\lambda = 5$, $n = 6, 8, 10, 15, 20, 50$



Poisson y binomial (cont.)

- ▶ Esta es, de hecho, la motivación para definir una VA de Poisson
- ▶ Sustituyendo $p = \lambda/n$ en la pmf de una VA binomial

$$\begin{aligned} p_n(x) &= \frac{n!}{(n-x)!x!} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x} \\ &= \frac{n(n-1)\dots(n-x+1)}{n^x} \frac{\lambda^x}{x!} \frac{(1-\lambda/n)^n}{(1-\lambda/n)^x} \end{aligned}$$

⇒ (usamos la def. de factorial y $(1-\lambda/n)^{n-x} = \frac{(1-\lambda/n)^n}{(1-\lambda/n)^x}$, y reordenamos)

- ▶ En el límite, el término rojo vale $\lim_{n \rightarrow \infty} (1-\lambda/n)^n = e^{-\lambda}$
- ▶ Los términos negro y azul convergen a 1. Luego,

$$\lim_{n \rightarrow \infty} p_n(x) = 1 \frac{\lambda^x}{x!} \frac{e^{-\lambda}}{1} = e^{-\lambda} \frac{\lambda^x}{x!}$$

⇒ El límite es la pmf de una VA de Poisson

- ▶ La distribución binomial está motivada por el conteo de aciertos
- ▶ La distribución de Poisson es una aproximación para grandes números de experimentos n
 - ⇒ La distribución de Poisson es más manejable (comparar pmfs)
- ▶ A veces se la refiere como la “ley de eventos raros”
 - ▶ Los eventos individuales (aciertos) suceden con probabilidad pequeña $p = \lambda/n$
 - ▶ Los eventos agregados (cantidad de aciertos), sin embargo, no tienen por qué ser raros
- ▶ Notar que las cuatro VAs vistas hasta ahora refieren a “tiradas de monedas”

Variables aleatorias continuas

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

VAs continuas, funciones de densidad de probabilidad

- ▶ Los valores posibles que toman las VAs continuas X forman un subconjunto denso $\mathcal{X} \subseteq \mathbb{R}$
 - ⇒ Cantidad infinita de valores **no numerables**
- ▶ La función de densidad de probabilidad (pdf) $f_X(x)$ es tal que para cualquier subconjunto $\mathcal{X} \subseteq \mathbb{R}$
(A la derecha, pdf normal)



$$P(X \in \mathcal{X}) = \int_{\mathcal{X}} f_X(x) dx$$

⇒ **Tenemos $P(X = x) = 0$ para todo $x \in \mathcal{X}$**

- ▶ La cdf definida como antes y relacionada a la (A la derecha, cdf normal)

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(u) du$$

$$\Rightarrow P(X \leq \infty) = F_X(\infty) = \lim_{x \rightarrow \infty} F_X(x) = 1$$



- ▶ Cuando el conjunto $\mathcal{X} = [a, b]$ es un intervalo de \mathbb{R}

$$P(X \in [a, b]) = P(X \leq b) - P(X \leq a) = F_X(b) - F_X(a)$$

- ▶ En términos de la pdf se puede escribir como

$$P(X \in [a, b]) = \int_a^b f_X(x) dx$$

- ▶ Para intervalos pequeños $[x_0, x_0 + \delta x]$, en particular

$$P(X \in [x_0, x_0 + \delta x]) = \int_{x_0}^{x_0 + \delta x} f_X(x) dx \approx f_X(x_0) \delta x$$

⇒ La probabilidad es el “área bajo la pdf” (de dónde el nombre “densidad”)

- ▶ Otra relación entre pdf y cdf es $\Rightarrow \frac{\partial F_X(x)}{\partial x} = f_X(x)$

⇒ Teorema fundamental del cálculo


Distribución uniforme

- ▶ Modela problemas con probabilidades equiprobables en $[a, b]$
- ▶ La pdf de una VA **uniforme** es $f(x) = 0$ fuera de $[a, b]$, y


$$f(x) = \frac{1}{b-a}, \quad \text{para } a \leq x \leq b$$

- ▶ La cdf es $F(x) = (x - a)/(b - a)$ en el intervalo $[a, b]$ (0 antes, 1 después)
- ▶ La prob. del intervalo $[\alpha, \beta] \subseteq [a, b]$ es $\int_{\alpha}^{\beta} f(x)dx = (\beta - \alpha)/(b - a)$
⇒ Solo depende del ancho $\beta - \alpha$ del intervalo, no de su posición

pdf ($a = -1, b = 1$)



cdf ($a = -1, b = 1$)



Distribución exponencial

- ▶ Duración de llamadas de teléfono, vida de componentes electrónicos
- ▶ La pdf de una VA exponencial es


$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

⇒ Cuando λ crece, al “altura” aumenta y el “ancho” disminuye


- ▶ La cdf se obtiene integrando la pdf

$$F(x) = \int_{-\infty}^x f(u) du = \int_0^x \lambda e^{-\lambda u} du = -e^{-\lambda u} \Big|_0^x = 1 - e^{-\lambda x}$$

pdf ($\lambda = 1$)





cdf ($\lambda = 1$)



Distribución Normal o Gaussiana

- ▶ Modela la aleatoriedad que surge de un gran número de efectos aleatorios
- ▶ La pdf de una VA normal es $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2}$
 - ⇒ μ es la media (centro), σ^2 es la varianza (ancho)
 - ⇒ 0,68 prob. between $\mu \pm \sigma$, 0,997 prob. in $\mu \pm 3\sigma$
 - ⇒ Una VA normal estándar tiene $\mu = 0$ y $\sigma^2 = 1$
- ▶ La cdf $F(x)$ no se puede expresar en términos de funciones elementales



Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

- ▶ Se nos pide que resumamos la información sobre una VA en un único valor,
 - ⇒ ¿cuál debería ser ese valor?
- ▶ Si se nos pidiera una descripción con unos pocos valores,
 - ⇒ ¿cuáles deberían ser esos valores?
- ▶ Los valores esperados (medias) son respuestas convenientes a estas preguntas
- ▶ **Atención:** Las esperanzas son descripciones condensadas
 - ⇒ No capturan todos los aspectos del fenómeno aleatorio
 - ⇒ La historia completa es contada por la distribución de probabilidad (cdf)

Definición para VAs discretas

- ▶ La VA discreta X toma valores x_i , $i = 1, 2, \dots$ con pmf $p(x)$
- ▶ **Def:** El **valor esperado** de la VA **discreta** X es

$$\mathbb{E}[X] := \sum_{i=1}^{\infty} x_i p(x_i) = \sum_{x:p(x)>0} xp(x)$$

- ▶ Es el promedio ponderado sobre los valores posibles x_i . **Las probabilidades son pesos**
- ▶ Es el promedio común si la VA toma valores x_i , $i = 1, \dots, N$ equiprobables

$$\mathbb{E}[X] = \sum_{i=1}^N x_i p(x_i) = \sum_{i=1}^N x_i \frac{1}{N} = \frac{1}{N} \sum_{i=1}^N x_i$$

Valor esperado de VAs de Bernoulli y geométrica

Ej: Para una VA **Bernoulli** $p(x) = p^x q^{1-x}$, for $x \in \{0, 1\}$

$$\mathbb{E}[X] = 1 \times p + 0 \times q = p$$

Ej: Para una VA **geométrica** $p(x) = p(1-p)^{x-1} = pq^{x-1}$, para $x \geq 1$

- ▶ Notar que $\partial q^x / \partial q = xq^{x-1}$ y que las derivadas son operadores lineales

$$\mathbb{E}[X] = \sum_{x=1}^{\infty} x p q^{x-1} = p \sum_{x=1}^{\infty} \frac{\partial q^x}{\partial q} = p \frac{\partial}{\partial q} \left(\sum_{x=1}^{\infty} q^x \right)$$

- ▶ La suma dentro de la derivada es una geométrica. Vale $q/(1-q)$, de dónde

$$\mathbb{E}[X] = p \frac{\partial}{\partial q} \left(\frac{q}{1-q} \right) = \frac{p}{(1-q)^2} = \frac{1}{p}$$

- ▶ El tiempo hasta el primer acierto es el inverso de la probabilidad de acierto. Razonable

Valor esperado de una VA Poisson

Ej: Para una VA **Poisson** $p(x) = e^{-\lambda}(\lambda^x/x!)$, for $x \geq 0$

- ▶ El primer sumando en la definición es 0; luego sacamos λ para afuera y usamos $\frac{x}{x!} = \frac{1}{(x-1)!}$

$$\mathbb{E}[X] = \sum_{x=0}^{\infty} x e^{-\lambda} \frac{\lambda^x}{x!} = \lambda e^{-\lambda} \sum_{x=1}^{\infty} \frac{\lambda^{x-1}}{(x-1)!}$$

- ▶ La suma es la serie de Taylor de $e^{\lambda} = 1 + \lambda + \lambda^2/2! + \dots + \lambda^x/x!$

$$\mathbb{E}[X] = \lambda e^{-\lambda} e^{\lambda} = \lambda$$

- ▶ **Poisson es el límite de la binomial para grandes números n , con $\lambda = np$**

⇒ Cuenta cantidad de aciertos en n experimentos, con probabilidad p

- ▶ El número esperado de aciertos es $\lambda = np$
⇒ **Cantidad de experimentos \times probabilidad de acierto individual.**

Razonable

Definición para VAs continuas

- ▶ VA continua X toma valores en \mathbb{R} con pdf $f(x)$
- ▶ **Def:** El **valor esperado** de la VA **continua** X es

$$\mathbb{E}[X] := \int_{-\infty}^{\infty} xf(x) dx$$

- ▶ Comparar con $\mathbb{E}[X] := \sum_{x:p(x)>0} xp(x)$ para el caso discreto
- ▶ Notar que la integral y la suma se suponen definidas
⇒ De no ser así decimos que **la esperanza no existe**

Valor esperado de una VA normal

Ej: Para una VA **normal**, sumamos y restamos μ , y separamos integrales

$$\begin{aligned}\mathbb{E}[X] &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} x e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \\ &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} (x + \mu - \mu) e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \\ &= \mu \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx + \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} (x - \mu) e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx\end{aligned}$$

- ▶ La **primera integral** vale 1 ya que integra una pdf en todo \mathbb{R}
- ▶ La **segunda integral** es 0 por simetría. Resulta

$$\mathbb{E}[X] = \mu$$

- ▶ La **media** de una VA con pdf simétrica es el punto de simetría

Valores esperados de VAs uniforme y exponencial

Ej: Para una VA **uniforme** $f(x) = 1/(b - a)$, para todo $a \leq x \leq b$

$$\mathbb{E}[X] = \int_{-\infty}^{\infty} xf(x) dx = \int_a^b \frac{x}{b-a} dx = \frac{b^2 - a^2}{2(b-a)} = \frac{(a+b)}{2}$$

- Tiene sentido ya que la pdf es **simétrica** con respecto al punto medio $(a+b)/2$

Ex: Para una VA **exponencial** integramos por partes

$$\begin{aligned}\mathbb{E}[X] &= \int_0^{\infty} x\lambda e^{-\lambda x} dx \\ &= -xe^{-\lambda x} \Big|_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx \\ &= -xe^{-\lambda x} \Big|_0^{\infty} - \frac{e^{-\lambda x}}{\lambda} \Big|_0^{\infty} = \frac{1}{\lambda}\end{aligned}$$

Valor esperado de una función de una VA

- ▶ Consideremos una función $g(X)$ de una VA X . ¿Valor esperado de $g(X)$?
- ▶ $g(X)$ es una VA, por lo que tiene una pmf $p_{g(X)}(g(x))$

$$\mathbb{E}[g(X)] = \sum_{g(x): p_{g(X)}(g(x)) > 0} g(x) p_{g(X)}(g(x))$$

⇒ Requiere calcular la pmf de $g(X)$. Hay una forma simple de hacerlo

Teorema

Sea $g(X)$ una función de una VA discreta X con pmf $p_X(x)$. Entonces

$$\mathbb{E}[g(X)] = \sum_{i=1}^{\infty} g(x_i) p_X(x_i)$$

- ▶ Suma ponderada de valores funcionales. No es necesario calcular la pmf de $g(X)$
- ▶ Lo mismo vale para X va continua

$$\mathbb{E}[g(X)] = \int_{-\infty}^{\infty} g(x) f_X(x) dx$$

Valor esperado para una función lineal de una VA

- ▶ Consideremos la **función afín** $g(X) = aX + b$

$$\begin{aligned}\mathbb{E}[aX + b] &= \sum_{i=1}^{\infty} (ax_i + b)p_X(x_i) \\ &= \sum_{i=1}^{\infty} ax_i p_X(x_i) + \sum_{i=1}^{\infty} bp_X(x_i) \\ &= a \sum_{i=1}^{\infty} x_i p_X(x_i) + b \sum_{i=1}^{\infty} p_X(x_i) \\ &= a\mathbb{E}[X] + b1\end{aligned}$$

- ▶ Se puede intercambiar la esperanza con constantes aditivas o multiplicativas

$$\mathbb{E}[aX + b] = a\mathbb{E}[X] + b$$

⇒ Vale lo mismo para VAs continuas (linealidad de la integral)

Valor esperado de una función indicatriz

- ▶ Sean X una VA y \mathcal{X} un conjunto

$$\mathbb{I}\{X \in \mathcal{X}\} = \begin{cases} 1, & \text{if } x \in \mathcal{X} \\ 0, & \text{if } x \notin \mathcal{X} \end{cases}$$

- ▶ El valor esperado de $\mathbb{I}\{X \in \mathcal{X}\}$ en el caso discreto es

$$\mathbb{E}[\mathbb{I}\{X \in \mathcal{X}\}] = \sum_{x: p_X(x) > 0} \mathbb{I}\{x \in \mathcal{X}\} p_X(x) = \sum_{x \in \mathcal{X}} p_X(x) = \mathbf{P}(X \in \mathcal{X})$$

- ▶ De la misma forma, para el caso continuo

$$\mathbb{E}[\mathbb{I}\{X \in \mathcal{X}\}] = \int_{-\infty}^{\infty} \mathbb{I}\{x \in \mathcal{X}\} f_X(x) dx = \int_{x \in \mathcal{X}} f_X(x) dx = \mathbf{P}(X \in \mathcal{X})$$

- ▶ Valor esperado de la indicatriz = Probabilidad del suceso correspondiente

⇒ Recordar que $\mathbb{E}[X] = p$ para una VA Bernoulli (“indica acierto”)

Momentos, momentos centrados y varianza

- ▶ **Def:** El **momento de orden n** ($n \geq 0$) de una VA es

$$\mathbb{E}[X^n] = \sum_{i=1}^{\infty} x_i^n p(x_i)$$

- ▶ **Def:** El **momento centrado de orden n** corrige el sesgo de la media, esto es

$$\mathbb{E}\left[(X - \mathbb{E}[X])^n\right] = \sum_{i=1}^{\infty} (x_i - \mathbb{E}[X])^n p(x_i)$$

- ▶ Momento de orden 0: $\mathbb{E}[X^0] = 1$; momento de orden 1: es la media $\mathbb{E}[X]$
- ▶ El momento centrado de orden 2 es la **varianza**. Mide el **ancho de la pmf**

$$\text{var}[X] = \mathbb{E}\left[(X - \mathbb{E}[X])^2\right] = \mathbb{E}[X^2] - \mathbb{E}^2[X]$$

Ej: Para funciones afines

$$\text{var}[aX + b] = a^2 \text{var}[X]$$

Varianza de VAs Bernoulli y Poisson

Ex: Para una VA Bernoulli X de parámetro p , $\mathbb{E}[X] = \mathbb{E}[X^2] = p$

$$\Rightarrow \text{var}[X] = \mathbb{E}[X^2] - \mathbb{E}^2[X] = p - p^2 = p(1 - p)$$

Ej: Para una VA Poisson Y de parámetro λ , el segundo momento es

$$\begin{aligned}\mathbb{E}[Y^2] &= \sum_{y=0}^{\infty} y^2 e^{-\lambda} \frac{\lambda^y}{y!} = \sum_{y=1}^{\infty} y \frac{e^{-\lambda} \lambda^y}{(y-1)!} \\ &= \sum_{y=1}^{\infty} (y-1) \frac{e^{-\lambda} \lambda^y}{(y-1)!} + \sum_{y=1}^{\infty} \frac{e^{-\lambda} \lambda^y}{(y-1)!} \\ &= e^{-\lambda} \lambda^2 \sum_{y=2}^{\infty} \frac{\lambda^{y-2}}{(y-2)!} + e^{-\lambda} \lambda \sum_{y=1}^{\infty} \frac{\lambda^{y-1}}{(y-1)!} \\ &= e^{-\lambda} \lambda^2 e^{\lambda} + e^{-\lambda} \lambda e^{\lambda} = \lambda^2 + \lambda\end{aligned}$$

$$\Rightarrow \text{var}[Y] = \mathbb{E}[Y^2] - \mathbb{E}^2[Y] = \lambda^2 + \lambda - \lambda^2 = \lambda$$

Distribuciones de probabilidad conjunta

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

- ▶ Queremos estudiar problemas con más de una VA, e.g. X e Y
- ▶ Las distribuciones de probabilidad de X e Y **no son suficientes**
 - ⇒ La **distribución de probabilidad conjunta (cdf) of (X, Y)** se define como

$$F_{XY}(x, y) = P(X \leq x, Y \leq y)$$

- ▶ If X, Y claras del contexto, omitimos el subíndice: $F_{XY}(x, y) = F(x, y)$
- ▶ Podemos recuperar $F_X(x)$ considerando todos los valores posibles de Y

$$F_X(x) = P(X \leq x) = P(X \leq x, Y \leq \infty) = F_{XY}(x, \infty)$$

⇒ $F_X(x)$ y $F_Y(y) = F_{XY}(\infty, y)$ se llaman **cdfs marginales**

- ▶ Consideremos las VAs discretas X e Y
 X toma valores en $\mathcal{X} := \{x_1, x_2, \dots\}$ e Y en $\mathcal{Y} := \{y_1, y_2, \dots\}$

- ▶ La **pmf conjunta** de (X, Y) se define como

$$p_{XY}(x, y) = P(X = x, Y = y)$$

- ▶ Los valores posibles de (x, y) son elementos del producto Cartesiano $\mathcal{X} \times \mathcal{Y}$
 - ▶ $(x_1, y_1), (x_1, y_2), \dots, (x_2, y_1), (x_2, y_2), \dots, (x_3, y_1), (x_3, y_2), \dots$

- ▶ La pmf marginal $p_X(x)$ se obtiene sumando sobre todos los valores posibles de Y

$$p_X(x) = P(X = x) = \sum_{y \in \mathcal{Y}} P(X = x, Y = y) = \sum_{y \in \mathcal{Y}} p_{XY}(x, y)$$

⇒ De la misma forma $p_Y(y) = \sum_{x \in \mathcal{X}} p_{XY}(x, y)$. **Marginalizamos**

sumando

- ▶ Sean X, Y VAs continuas y $\mathcal{A} \subset \mathbb{R}^2$ un conjunto
- ▶ La **pdf conjunta** es una función $f_{XY}(x, y) : \mathbb{R}^2 \rightarrow \mathbb{R}^+$ tal que

$$P((X, Y) \in \mathcal{A}) = \iint_{\mathcal{A}} f_{XY}(x, y) dx dy$$

- ▶ **Marginalización.** Hay dos formas de escribir $P(X \in \mathcal{X})$

$$P(X \in \mathcal{X}) = P(X \in \mathcal{X}, Y \in \mathbb{R}) = \int_{\mathcal{X}} \int_{-\infty}^{+\infty} f_{XY}(x, y) dy dx$$

$$\Rightarrow \text{Definición de } f_X(x) \Rightarrow P(X \in \mathcal{X}) = \int_{\mathcal{X}} f_X(x) dx$$

- ▶ Tenemos entonces

$$\Rightarrow f_X(x) = \int_{-\infty}^{+\infty} f_{XY}(x, y) dy, \quad f_Y(y) = \int_{-\infty}^{+\infty} f_{XY}(x, y) dx$$

Ejemplo

- ▶ Sean B_1, B_2 VAs Bernoulli de igual parámetro p

$$\Rightarrow \text{Definimos } X = B_1, Y = B_1 + B_2$$

- ▶ La pmf de X es

$$p_X(0) = 1 - p, \quad p_X(1) = p$$

- ▶ De la misma forma, la pmf de Y es

$$p_Y(0) = (1 - p)^2, \quad p_Y(1) = 2p(1 - p), \quad p_Y(2) = p^2$$

- ▶ La pmf conjunta de X e Y es

$$\begin{aligned} p_{XY}(0,0) &= (1 - p)^2, & p_{XY}(0,1) &= p(1 - p), & p_{XY}(0,2) &= 0 \\ p_{XY}(1,0) &= 0, & p_{XY}(1,1) &= p(1 - p), & p_{XY}(1,2) &= p^2 \end{aligned}$$

- ▶ Por conveniencia es común agrupar las VAs en un vector
 - ⇒ La distribución de probabilidad de un vector es la distribución conjunta de sus elementos
- ▶ Sean por ejemplo dos VAs X e Y . El vector aleatorio es $\mathbf{X} = [X, Y]^T$
- ▶ Si X e Y son discretas, el vector \mathbf{X} es discreto con pmf

$$p_{\mathbf{X}}(\mathbf{x}) = p_{\mathbf{X}}([x, y]^T) = p_{XY}(x, y)$$

- ▶ Si X e Y son continuas, \mathbf{X} es continuo con pdf

$$f_{\mathbf{X}}(\mathbf{x}) = f_{\mathbf{X}}([x, y]^T) = f_{XY}(x, y)$$

- ▶ La cdf del vector es $\Rightarrow F_{\mathbf{X}}(\mathbf{x}) = F_{\mathbf{X}}([x, y]^T) = F_{XY}(x, y)$
- ▶ En general podemos definir VAs n -dimensionales
 $\mathbf{X} := [X_1, X_2, \dots, X_n]^T$

⇒ Es solo notación, las definiciones siguen del caso $n = 2$

Esperanzas conjuntas

Sigma-álgebras y espacios de probabilidad

Probabilidad condicional, probabilidad total, regla de Bayes

Independencia

Variables aleatorias

Variables aleatorias discretas

Variables aleatorias continuas

Valores esperados

Distribuciones de probabilidad conjunta

Esperanzas conjuntas

- ▶ X e Y VAs, $g(X, Y)$ función es también una VA
- ▶ El valor esperado de $g(X, Y)$ para X, Y VAs discretas se escribe

$$\mathbb{E}[g(X, Y)] = \sum_{x, y: p_{XY}(x, y) > 0} g(x, y) p_{XY}(x, y)$$

- ▶ Si X, Y VAs continuas

$$\mathbb{E}[g(X, Y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f_{XY}(x, y) dx dy$$

⇒ Podemos tener más de dos VAs y usar notación vectorial

Ej: Transformación lineal de un vector aleatorio $\mathbf{X} \in \mathbb{R}^n$: $g(\mathbf{X}) = \mathbf{a}^T \mathbf{X}$

$$\Rightarrow \mathbb{E}[\mathbf{a}^T \mathbf{X}] = \int_{\mathbb{R}^n} \mathbf{a}^T \mathbf{x} f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x}$$

Valor esperado de una suma de variables aleatorias

- ▶ Valor esperado de suma de dos VAs

$$\begin{aligned}\mathbb{E}[X + Y] &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x + y) f_{XY}(x, y) dx dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f_{XY}(x, y) dx dy + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y f_{XY}(x, y) dx dy\end{aligned}$$

- ▶ Luego,

$$\begin{aligned}\mathbb{E}[X + Y] &= \int_{-\infty}^{\infty} x \int_{-\infty}^{\infty} f_{XY}(x, y) dy dx + \int_{-\infty}^{\infty} y \int_{-\infty}^{\infty} f_{XY}(x, y) dx dy \\ &= \int_{-\infty}^{\infty} x f_X(x) dx + \int_{-\infty}^{\infty} y f_Y(y) dy \\ &= \mathbb{E}[X] + \mathbb{E}[Y]\end{aligned}$$

⇒ Usamos expresiones marginales

- ▶ Esperanza \leftrightarrow suma $\Rightarrow \mathbb{E}[\sum_i X_i] = \sum_i \mathbb{E}[X_i]$

La esperanza es un operador lineal

- ▶ Combinando $\mathbb{E}[X + Y] = \mathbb{E}[X] + \mathbb{E}[Y]$ y $\mathbb{E}[aX + b] = a\mathbb{E}[X] + b$ probamos que

$$\mathbb{E}[a_x X + a_y Y + b] = a_x \mathbb{E}[X] + a_y \mathbb{E}[Y] + b$$

- ▶ En notación vectorial ($\mathbf{a} \in \mathbb{R}^n$, $\mathbf{X} \in \mathbb{R}^n$, b escalar)

$$\mathbb{E}[\mathbf{a}^T \mathbf{X} + b] = \mathbf{a}^T \mathbb{E}[\mathbf{X}] + b$$

- ▶ También, si \mathbf{A} es una matriz $m \times n$ con filas $\mathbf{a}_1^T, \dots, \mathbf{a}_m^T$ y $\mathbf{b} \in \mathbb{R}^m$ un vector con elementos b_1, \dots, b_m , podemos escribir

$$\mathbb{E}[\mathbf{A}\mathbf{X} + \mathbf{b}] = \begin{pmatrix} \mathbb{E}[\mathbf{a}_1^T \mathbf{X} + b_1] \\ \mathbb{E}[\mathbf{a}_2^T \mathbf{X} + b_2] \\ \vdots \\ \mathbb{E}[\mathbf{a}_m^T \mathbf{X} + b_m] \end{pmatrix} = \begin{pmatrix} \mathbf{a}_1^T \mathbb{E}[\mathbf{X}] + b_1 \\ \mathbf{a}_2^T \mathbb{E}[\mathbf{X}] + b_2 \\ \vdots \\ \mathbf{a}_m^T \mathbb{E}[\mathbf{X}] + b_m \end{pmatrix} = \mathbf{A}\mathbb{E}[\mathbf{X}] + \mathbf{b}$$

- ▶ La esperanza conmuta con operadores lineales

Independencia de VAs

- ▶ Los sucesos E y F son independientes si $P(E \cap F) = P(E)P(F)$
- ▶ **Def:** Las VAs X e Y son **independientes** si los sucesos $\{X \leq x\}$ y $\{Y \leq y\}$ son independiente cualquiera sea x e y , i.e.

$$P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y)$$

⇒ Por definición, esto es equivalente a $F_{XY}(x, y) = F_X(x)F_Y(y)$

- ▶ Para VAs discretas, es equivalente a la relación análoga con pmfs

$$p_{XY}(x, y) = p_X(x)p_Y(y)$$

- ▶ Para VAs continuas vale en análogo para pdfs

$$f_{XY}(x, y) = f_X(x)f_Y(y)$$

- ▶ **Independencia** \Leftrightarrow La distribución conjunta se factoriza como producto de marginales

Suma de VAs de Poisson independientes

- ▶ X, Y VAs Poisson de parámetros λ_x y λ_y , **Independientes**
- ▶ **Q:** ¿Distribución de probabilidad de la VA $Z := X + Y$?
- ▶ $Z = n$ solo si $X = k, Y = n - k$ para algún $0 \leq k \leq n$

$$\begin{aligned} p_Z(n) &= \sum_{k=0}^n P(X = k, Y = n - k) = \sum_{k=0}^n P(X = k) P(Y = n - k) \\ &= \sum_{k=0}^n e^{-\lambda_x} \frac{\lambda_x^k}{k!} e^{-\lambda_y} \frac{\lambda_y^{n-k}}{(n-k)!} = \frac{e^{-(\lambda_x + \lambda_y)}}{n!} \sum_{k=0}^n \frac{n!}{(n-k)! k!} \lambda_x^k \lambda_y^{n-k} \\ &= \frac{e^{-(\lambda_x + \lambda_y)}}{n!} (\lambda_x + \lambda_y)^n \end{aligned}$$

- ▶ Z es Poisson de parámetro $\lambda_z := \lambda_x + \lambda_y$
⇒ **La suma de VAs de Poisson independientes es Poisson** (el parámetro es la suma de los parámetros originales)

Valor esperado de una VA binomial

- ▶ Las VAs binomiales cuentan cantidad de aciertos en n experimentos

Ej: Sean X_i , $i = 1, \dots, n$ VAs de Bernoulli **independientes**

- ▶ Podemos escribir la binomial como $X = \sum_{i=1}^n X_i$

$$\Rightarrow \mathbb{E}[X] = \sum_{i=1}^n \mathbb{E}[X_i] = np$$

- ▶ **Cantidad esperada de aciertos = cantidad de experimentos \times prob. individual de acierto**
 - ▶ Misma interpretación que vimos para VAs de Poisson

Ej: VAs Bernoulli **dependientes**. $Y = \sum_{i=1}^n X_i$, pero los X_i no son independientes

- ▶ La cantidad esperada de aciertos sigue siendo $\mathbb{E}[Y] = np$
 - ▶ **La linealidad de la esperanza no requiere independencia**
 - ▶ Y no sigue una distribución binomial

Valor esperado de un producto de VAs independientes

Teorema

Para VAs X , Y *independientes* y funciones $g(X)$, $h(Y)$ arbitrarias:

$$\mathbb{E}[g(X)h(Y)] = \mathbb{E}[g(X)]\mathbb{E}[h(Y)]$$

El valor esperado del producto es el producto de los valores esperados

- ▶ Se demuestra que $g(X)$ y $h(Y)$ también son independientes.

Intuitivo

Ej: Caso especial cuando $g(X) = X$ y $h(Y) = Y$ se tiene

$$\mathbb{E}[XY] = \mathbb{E}[X]\mathbb{E}[Y]$$

- ▶ **Esperanzas y productos se pueden intercambiar si las VAs son independientes**
- ▶ Es distinto cuando las operaciones son lineales (**siempre es posible conmutar**)

Valor esperado de un producto de VAs independientes (cont.)

Demostración.

- Supongamos X, Y VAs continuas. Usamos la definición de independencia

$$\begin{aligned}\mathbb{E}[g(X)h(Y)] &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x)h(y)f_{XY}(x, y) dx dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x)h(y)f_X(x)f_Y(y) dx dy\end{aligned}$$

- El integrando es el producto de una función de x y una función de y

$$\begin{aligned}\mathbb{E}[g(X)h(Y)] &= \int_{-\infty}^{\infty} g(x)f_X(x) dx \int_{-\infty}^{\infty} h(y)f_Y(y) dy \\ &= \mathbb{E}[g(X)] \mathbb{E}[h(Y)]\end{aligned}$$



Varianza de una suma de VAs independientes

- ▶ Sean X_n , $n = 1, \dots, N$ independientes, con $\mathbb{E}[X_n] = \mu_n$, $\text{var}[X_n] = \sigma_n^2$
- ▶ **Q:** ¿Varianza de la suma $X := \sum_{n=1}^N X_n$?
- ▶ Nótese que la media de X es $\mathbb{E}[X] = \sum_{n=1}^N \mu_n$. Luego

$$\text{var}[X] = \mathbb{E} \left[\left(\sum_{n=1}^N X_n - \sum_{n=1}^N \mu_n \right)^2 \right] = \mathbb{E} \left[\left(\sum_{n=1}^N (X_n - \mu_n) \right)^2 \right]$$

- ▶ Desarrollando e intercambiando suma y esperanza

$$\text{var}[X] = \sum_{n=1}^N \sum_{m=1}^N \mathbb{E} \left[(X_n - \mu_n)(X_m - \mu_m) \right]$$

Varianza de una suma de VAs independientes (cont.)

- ▶ Separamos auto-productos y productos cruzados. Luego usamos independencia, y $\mathbb{E}(X_n - \mu_n) = 0$

$$\begin{aligned}\text{var}[X] &= \sum_{n=1, n \neq m}^N \sum_{m=1}^N \mathbb{E}[(X_n - \mu_n)(X_m - \mu_m)] + \sum_{n=1}^N \mathbb{E}[(X_n - \mu_n)^2] \\ &= \sum_{n=1, n \neq m}^N \sum_{m=1}^N \mathbb{E}(X_n - \mu_n)\mathbb{E}(X_m - \mu_m) + \sum_{n=1}^N \sigma_n^2 = \sum_{n=1}^N \sigma_n^2\end{aligned}$$

- ▶ Si las VAs son independientes \Rightarrow La varianza de la suma es la suma de las varianzas
- ▶ Hay resultados más generales para VAs independientes X_i , $i = 1, \dots, n$

$$\text{var} \left[\sum_i (a_i X_i + b_i) \right] = \sum_i a_i^2 \text{var}[X_i]$$

Varianza de una VA binomial y media muestral

Ej: Sean X_i , $i = 1, \dots, n$ VAs Bernoulli independientes de parámetro p
 \Rightarrow Recordemos que $\mathbb{E}[X_i] = p$ y $\text{var}[X_i] = p(1 - p)$

► Escribimos la VA binomial X de parámetros (n, p) como: $X = \sum_{i=1}^n X_i$

► La varianza de la binomial es entonces

$$\Rightarrow \text{var}[X] = \sum_{i=1}^n \text{var}[X_i] = np(1 - p)$$

Ej: Sean Y_i , $i = 1, \dots, n$ VAs independientes con $\mathbb{E}[Y_i] = \mu$,
 $\text{var}[Y_i] = \sigma^2$

► La media muestral es $\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$. ¿Cuánto valen $\mathbb{E}[\bar{Y}]$ y $\text{var}[\bar{Y}]$?

► Valor esperado $\Rightarrow \mathbb{E}[\bar{Y}] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[Y_i] = \mu$

► Varianza $\Rightarrow \text{var}[\bar{Y}] = \frac{1}{n^2} \sum_{i=1}^n \text{var}[Y_i] = \frac{\sigma^2}{n}$ (independencia)

- ▶ **Def:** La **covarianza de X and Y** es (generaliza la varianza a pares de VAs)

$$\text{cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]$$

- ▶ Si $\text{cov}(X, Y) = 0$ las VAs X, Y se dicen **no correlacionadas**
- ▶ Si X, Y son independientes entonces $\mathbb{E}[XY] = \mathbb{E}[X]\mathbb{E}[Y]$ y $\text{cov}(X, Y) = 0$
 - ⇒ **La independencia implica no correlación**
- ▶ El inverso **no** vale, puede ser $\text{cov}(X, Y) = 0$ para X, Y dependientes
 - ▶ Ej: X uniforme en $[-a, a]$ y $Y = X^2$
 - ⇒ **Pero si X, Y son normales, correlación nula implica independencia**
- ▶ Si $\text{cov}(X, Y) > 0$ entonces X e Y tienden a moverse en la misma dirección
 - ⇒ **Correlación positiva**
- ▶ Si $\text{cov}(X, Y) < 0$ entonces X e Y tienden a moverse en direcciones opuestas
 - ⇒ **Correlación negativa**

Ejemplo de covarianza

- ▶ Sea X señal aleatoria de media nula y Z ruido de media nula
⇒ Supongamos que la señal X y el ruido Z son independientes
- ▶ Consideremos las señales recibidas $Y_1 = X + Z$ e $Y_2 = -X + Z$
- (I) Y_1 y X están **correlacionadas positivamente** (X , Y_1 se mueven en la misma dirección)

$$\begin{aligned}\text{cov}(X, Y_1) &= \mathbb{E}[XY_1] - \mathbb{E}[X]\mathbb{E}[Y_1] \\ &= \mathbb{E}[X(X + Z)] - \mathbb{E}[X]\mathbb{E}[X + Z]\end{aligned}$$

- ▶ El segundo término es 0 ($\mathbb{E}[X] = 0$). Para el primer término usamos la independencia de X , Z

$$\mathbb{E}[X(X + Z)] = \mathbb{E}[X^2] + \mathbb{E}[X]\mathbb{E}[Z] = \mathbb{E}[X^2]$$

- ▶ Combinando observaciones ⇒ **$\text{cov}(X, Y_1) = \mathbb{E}[X^2] > 0$**

Ejemplo de covarianza (cont.)

(II) Y_2 y X están **correlacionadas negativamente** (X , Y_2 se mueven en direcciones opuestas)

▶ Mismos cálculos $\Rightarrow \text{cov}(X, Y_2) = -\mathbb{E}[X^2] < 0$

(III) También podemos calcular la correlación entre Y_1 y Y_2

$$\begin{aligned}\text{cov}(Y_1, Y_2) &= \mathbb{E}[(X + Z)(-X + Z)] - \mathbb{E}[(X + Z)]\mathbb{E}[(-X + Z)] \\ &= -\mathbb{E}[X^2] + \mathbb{E}[Z^2]\end{aligned}$$

\Rightarrow Correlación negativa si $\mathbb{E}[X^2] > \mathbb{E}[Z^2]$ (ruido débil)

\Rightarrow Correlación positiva si $\mathbb{E}[X^2] < \mathbb{E}[Z^2]$ (ruido fuerte)

▶ Correlación entre X e Y_1 o entre X e Y_2 viene de la causalidad

▶ Correlación entre Y_1 e Y_2 no viene de la causalidad. **Variables latentes X y Z**

\Rightarrow **La correlación no implica causalidad**

Es un posible modelo (simple) de canal de comunicación