

Repaso de Probabilidad

Señales Aleatorias y Modulación

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería
Universidad de la República



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

2 de agosto de 2022

- ▶ Un **espacio de probabilidad** está determinado por la terna (Ω, \mathcal{F}, P) . Ω es el espacio muestral o universo de sucesos elementales, \mathcal{F} el conjunto de sucesos de Ω (sigma álgebra) y $P : \mathcal{F} \rightarrow (0, 1)$ (una función de \mathcal{F} en los reales).
- ▶ **La probabilidad es un instrumento de medida** que permite cuantificar la incertidumbre en la ocurrencia de los sucesos.

- ▶ **Def:** La probabilidad condicional de E dado F es (necesitamos que $P(F) > 0$)

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

- ▶ Ley de probabilidad total

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

$F_i, i = 1, 2, \dots$ es una **partición** de Ω (posiblemente infinita), de conjuntos son **disjuntos** ($\Rightarrow F_i \cap F_j = \emptyset$ para $i \neq j$) y que **cobren el espacio** ($\Rightarrow \bigcup_{i=1}^{\infty} F_i = \Omega$)

► 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),

⇒ $P(E | F)$, prob. que el pasado (E) haya visto el futuro (F)

⇒ $P(F | E)$, proba. que el futuro (F) corresponda al pasado (E)

- ▶ **Def:** los sucesos E y F son **independientes** si $P(E \cap F) = P(E)P(F)$
⇒ Sucesos que no son independientes son **dependientes**
- ▶ De la definición de probabilidad condicional

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

Intuitivamente, **conocer F no altera nuestra percepción sobre E , F no contiene información sobre E** . El recíproco también es cierto:
 $P(F | E) = P(F)$

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

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

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

- ▶ 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: 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

Variables aleatorias discretas

- ▶ Las **VA discretas** toman, a lo sumo, un conjunto **numerable** de valores

Están completamente caracterizadas por su **Función de (masa de) probabilidad** o **probability mass function (pmf)** $p_X(x) = P(X = x)$


- ▶ Si X tiene soporte $\{x_1, x_2, \dots\}$, su **pmf** satisface

- $p(x_i) > 0$ para $i = 1, 2, \dots$
- $p(x) = 0$ para todo $x \neq x_i$
- $\sum_{i=1}^{\infty} p(x_i) = 1$

- ▶ **Función de distribución (acumulada) (cdf)**

$$F_X(x) = P(X \leq x) = \sum_{i: x_i \leq x} p(x_i)$$

⇒ **Función creciente con saltos en x_i**



Variables aleatorias continuas

- ▶ 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)

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

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



- ▶ 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)

Valor esperado: 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: 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 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

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

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

- ▶ 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

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

- ▶ Si 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**

Distribuciones de probabilidad conjunta: pmf conjunta

- ▶ 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

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

- ▶ 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 $X = [X, Y]^T$
- ▶ Si X e Y son discretas, el vector X es discreto con pmf

$$p_X(x) = p_X([x, y]^T) = p_{XY}(x, y)$$

- ▶ Si X e Y son continuas, X es continuo con pdf

$$f_X(x) = f_X([x, y]^T) = f_{XY}(x, y)$$

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

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

- ▶ 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

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

Valor esperado de una suma de variables aleatorias

- ▶ **Ejemplo:** 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** ↔ **suma** ⇒ $\mathbb{E}[\sum_i X_i] = \sum_i \mathbb{E}[X_i]$

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 ($a \in \mathbb{R}^n$, $X \in \mathbb{R}^n$, b escalar)

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

- ▶ 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 el análogo para pdfs

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

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

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**

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 , $i = 1, \dots, n$

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

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**