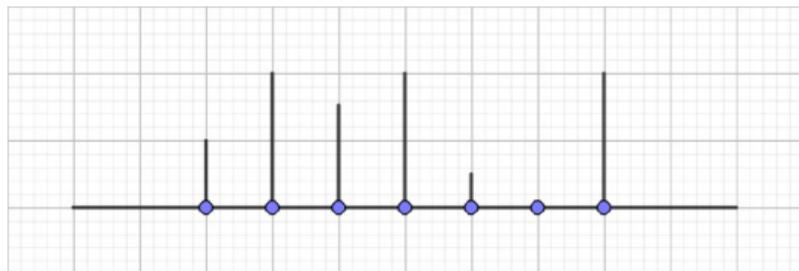


# **ESTADÍSTICOS**

ALAN REYES-FIGUEROA  
INTELIGENCIA ARTIFICIAL

(AULA 23) 15.ABRIL.2024



## Resúmenes de distribuciones:

- localización (promedio, rango, soporte o dominio);
- variabilidad (desviación estándar, varianza, entropía);
- forma de la distribución (kurtosis, histogramas, diagramas de probabilidad PP o QQ);
- simetría (sesgo, coeficiente de asimetría);
- En el caso de más variables: nos interesa algo que mida el grado de relación entre ellas (covarianza, correlación, información mutua).

# Estadísticos

Valores numéricos (o vectoriales) en términos de la variable aleatoria. Resumen de una distribución.

Existen estadísticos con varios propósitos: localización, variabilidad, ...

Promedio: El **promedio** o **esperanza** (*expectativa, valor esperado*) de una variable aleatoria discreta  $X$ ,  $\mathbb{E}(X)$ , se define como

$$\mathbb{E}(X) = \sum_x x \mathbb{P}(X = x).$$

en caso de que la suma exista.

Comentario: En la vida cotidiana usamos como promedio de  $\{x_i\}_{i=1}^n$  a

$$\frac{1}{n} \sum_{i=1}^n x_i.$$

En general,

## Definición

Dada una función  $g(\cdot)$ , se define la **esperanza**  $\mathbb{E}(g(X))$  como:

$$\mathbb{E}(g(X)) = \sum_x g(x) \mathbb{P}(X = x),$$

en caso de que la suma exista.

## Proposición

1. (Linealidad)  $\mathbb{E}(aX_1 + bX_2) = a\mathbb{E}(X_1) + b\mathbb{E}(X_2)$ .
2. (Independencia) Si  $X_1, X_2$  son independientes, entonces  $\mathbb{E}(X_1X_2) = \mathbb{E}(X_1) \mathbb{E}(X_2)$ .

# Esperanza

Prueba:

$$\begin{aligned}\mathbb{E}(aX_1 + bX_2) &= \sum_{\omega} (aX_1 + bX_2)(\omega)\mathbb{P}(\omega) = a \sum_{\omega} X_1(\omega)\mathbb{P}(\omega) + b \sum_{\omega} X_2(\omega)\mathbb{P}(\omega) \\ &= a\mathbb{E}(X_1) + b\mathbb{E}(X_2).\end{aligned}$$

Como  $X_1 \perp X_2$ , entonces  $\mathbb{P}(X_1 = x_1, X_2 = x_2) = \mathbb{P}(X_1 = x_1) \mathbb{P}(X_2 = x_2)$ . Luego

$$\begin{aligned}\mathbb{E}(X_1X_2) &= \sum_{(x_1, x_2)} (X_1X_2)(\omega)\mathbb{P}(X_1 = x_1, X_2 = x_2) \\ &= \sum_{(x_1, x_2)} X_1(x_1)X_2(x_2)\mathbb{P}(X_1 = x_1) \mathbb{P}(X_2 = x_2) \\ &= \left( \sum_{x_1} X_1(x_1) \mathbb{P}(x_1) \right) \left( \sum_{x_2} X_2(x_2) \mathbb{P}(x_2) \right) = \mathbb{E}(X_1) \mathbb{E}(X_2).\end{aligned}$$

# Ejemplo

a) ¿Cuál es la esperanza de una v.a. constante?

b) Calcular  $\mathbb{E}(3X + 2\mathbb{E}X)$ .

Solución:

a)  $\mathbb{E}(X) = \sum_x x \mathbb{P}(X = x) = c, \mathbb{P}(X = c) = c(1) = c.$

b)  $\mathbb{E}(3X + 2\mathbb{E}X) = 3\mathbb{E}(X) + 2\mathbb{E}(\mathbb{E}X) = 3\mathbb{E}(X) + 2\mathbb{E}(X) = 5\mathbb{E}(X).$

# Media, mediana y moda

Media: Sea una variable aleatoria discreta  $X$  con probabilidad  $\mathbb{P}$ . La **esperanza** (*expectativa, valor esperado*) de  $X$  se define como

$$\mathbb{E}(X) = \sum_x x \mathbb{P}(X = x).$$

Mediana: Una **mediana** de  $X$  es cualquier valor  $t \in \mathbb{R}$  que satisface  $F_X(t) = \frac{1}{2}$ . Dicho de otra manera, son las preimágenes  $F_X^{-1}(1/2)$ .

**Obs!**  $F_X$  en general no es invertible!! Denotamos  $Q_X : [0, 1] \rightarrow \overline{\mathbb{R}}$  a la *función de cuantiles*, la inversa generalizada de  $F_X$ :

$$Q_X(\alpha) = \sup\{x \in \mathbb{R} : F_X(x) \leq \alpha\}, \quad \text{para } 0 < \alpha < 1.$$

**Obs!** Existen cuatro formas de definir la función de cuantiles. Para  $0 < \alpha < 1$ :

- $Q_X(\alpha) = \sup\{x \in \mathbb{R} : F_X(x) \leq \alpha\}$ .
- $Q_X(\alpha) = \sup\{x \in \mathbb{R} : F_X(x) < \alpha\}$ .
- $Q_X(\alpha) = \inf\{x \in \mathbb{R} : F_X(x) \geq \alpha\}$ .
- $Q_X(\alpha) = \inf\{x \in \mathbb{R} : F_X(x) > \alpha\}$ .

En general, las cuatro definiciones dan resultados distintos (aunque pueden coincidir en función de las propiedades de la distribución y del punto en que se aplica).

Moda: Una **moda** de la distribución de  $X$  es cualquier máximo local de  $f_X$ . (unimodal, bimodal, ...)

El valor esperado  $\mathbb{E}(X)$  tiene otra propiedad importante: es el valor constante que minimiza la suma de errores cuadrados. Dado  $\{x_i\}_{i=1}^n$  la imagen de la v.a.  $X$ , sea  $p_i = \mathbb{P}(X = x_i)$ . Queremos

$$\text{minimizar } J(c) = \text{minimizar } \sum_{i=1}^n p_i (x_i - c)^2.$$

Solución: Derivando con respecto de  $c$ , obtenemos  $J'(c) = 2 \sum_{i=1}^n p_i (x_i - c) = 0$ .  
Luego  $\sum_{i=1}^n p_i x_i = c \sum_{i=1}^n p_i = c \Rightarrow c = \frac{\sum_{i=1}^n p_i x_i}{\sum_{i=1}^n p_i} = \sum_{i=1}^n x_i \mathbb{P}(X = x_i) = \mathbb{E}(X)$ .

- El valor que minimiza  $\sum_{i=1}^n p_i |x_i - c|_1$  es: la *mediana* de  $X$ .
- El valor que minimiza  $\sum_{i=1}^n p_i |x_i - c|_0$  es: la *moda* de  $X$ .

# Esperanza condicional

## Definición

Para la v.a.  $X$  y para un evento  $A \in \mathcal{F}$ , se define el **promedio condicional** (o **esperanza condicional**) de  $X$  dado  $A$  como

$$\mathbb{E}(X | A) = \sum_x x \mathbb{P}(X = x | A).$$

## Definición

Para las v.a.  $X$  y  $Y$ , se define la **esperanza condicional** de  $X$  dado que  $Y$  es igual a un valor  $y$ , como

$$\mathbb{E}(X | Y = y) = \sum_x x \mathbb{P}(X = x | Y = y).$$

- En la práctica se suele abreviar  $\mathbb{E}(X | Y = y)$  como  $\mathbb{E}(X | Y)$ .

# Esperanza condicional

En general, definimos  $\mathbb{E}(g(X) | Y = y) = \sum_x g(x) \mathbb{P}(X = x | Y = y)$ .

## Proposición

Sean  $X, Y, Z$  v.a.,  $a, b \in \mathbb{R}$  y  $g : \mathbb{R} \rightarrow \mathbb{R}$ .

1.  $\mathbb{E}(a | Y) = a$ .
2.  $\mathbb{E}(aX + bZ | Y) = a\mathbb{E}(X | Y) + b\mathbb{E}(Z | Y)$ .
3.  $\mathbb{E}(X | Y) \geq 0$  si  $X \geq 0$ .
4.  $\mathbb{E}(X | Y) = \mathbb{E}(X)$  si  $X, Y$  son independientes.
5.  $\mathbb{E}(\mathbb{E}(X | Y)) = \mathbb{E}(X)$ .
6.  $\mathbb{E}(Xg(Y) | Y) = g(Y)\mathbb{E}(X | Y)$ . En particular,  $\mathbb{E}(g(Y) | Y) = g(Y)$ .
7.  $\mathbb{E}(X | Y, g(Y)) = \mathbb{E}(X | Y)$ .
8.  $\mathbb{E}(\mathbb{E}(X | Y, Z) | Y) = \mathbb{E}(X | Y)$ .

## Proposición (Ley de la probabilidad total para esperanzas)

Sean  $X, Y$  v.a. discretas, entonces

$$\mathbb{E}(X) = \sum_y \mathbb{E}(X | Y = y) \mathbb{P}(Y = y).$$

Ejemplo: Alguien anda perdido en la subterránea de Guanajuato. Está en un cruce con 3 opciones. Un camino le lleva a la salida en 10 minutos en promedio, un segundo camino le regresa a su lugar en promedio 15 minutos y un tercer camino le regresa a su lugar en promedio 5 minutos. Siempre elige alguna opción, independiente del pasado. ¿Cuánto va a tardar en promedio para salir?

# Esperanza condicional

## Solución:

- Opción 1: salida del subterráneo en 10m promedio.
- Opción 2: regresa al mismo lugar en 15m promedio.
- Opción 3: regresa al mismo lugar en 5m promedio.

Definimos  $E_i$  = elegir opción  $i$ ,  $i = 1, 2, 3$ .  $T$  la v.a. = tiempo de salida.

$$\begin{aligned}\mathbb{E}(T) &= \sum_{i=1}^3 \mathbb{E}(T | E_i) \mathbb{P}(E_i) \\ &= \mathbb{E}(T | E_1) \cdot \frac{1}{3} + \mathbb{E}(T | E_2) \cdot \frac{1}{3} + \mathbb{E}(T | E_3) \cdot \frac{1}{3} \\ &= (10m) \cdot \frac{1}{3} + (15m + \mathbb{E}(T)) \cdot \frac{1}{3} + \mathbb{E}(5m + \mathbb{E}(T)) \cdot \frac{1}{3} \\ &= \frac{10}{3}m + \frac{15}{3}m + \frac{5}{3}m + \frac{2}{3}\mathbb{E}(T).\end{aligned}$$

Luego,  $\frac{1}{3}\mathbb{E}(T) = 10m \Rightarrow \mathbb{E}(T) = 30m$ .

## Definición

Sea  $X$  una v.a. en  $\mathbb{R}$ . Definimos su **varianza** como:

$$\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}X)^2] = \mathbb{E}(X^2) - (\mathbb{E}(X))^2,$$

en caso de que este valor esperado exista.

Propiedades:

- $\text{Var}(X) \geq 0$ .
- $\text{Var}(aX) = a^2\text{Var}(X)$ .
- Si  $X_1, X_2$  son independientes, entonces

$$\text{Var}(aX_1 + bX_2) = a^2\text{Var}(X_1) + b^2\text{Var}(X_2).$$

Prueba:

- 

$$\text{Var}(X) = \mathbb{E}((X - \mathbb{E}X)^2) = \sum_x (\cdot)^2 \mathbb{P}(\cdot) \geq 0,$$

por ser suma de términos no-negativos.

- 

$$\begin{aligned}\text{Var}(aX) &= \mathbb{E}((aX - \mathbb{E}(aX))^2) = \mathbb{E}((aX - a\mathbb{E}X)^2) \\ &= \mathbb{E}(a^2(X - \mathbb{E}X)^2) = a^2\mathbb{E}((X - \mathbb{E}X)^2) \\ &= a^2\text{Var}(X).\end{aligned}$$

Prueba: Suponga que  $X_1, X_2$  son independientes. Entonces,  $\mathbb{E}(X_1X_2) = \mathbb{E}(X_1) \mathbb{E}(X_2)$ . Luego

$$\begin{aligned} \text{Var}(aX_1 + bX_2) &= \mathbb{E}([(aX_1 + bX_2) - \mathbb{E}(aX_1 + bX_2)]^2) \\ &= \mathbb{E}([a(X_1 - \mathbb{E}X_1) + b(X_2 - \mathbb{E}X_2)]^2) \\ &= \mathbb{E}(a^2(X_1 - \mathbb{E}X_1)^2 + b^2(X_2 - \mathbb{E}X_2)^2 + 2ab(X_1 - \mathbb{E}X_1)(X_2 - \mathbb{E}X_2)) \\ &= a^2\mathbb{E}((X_1 - \mathbb{E}X_1)^2) + b^2\mathbb{E}((X_2 - \mathbb{E}X_2)^2) + 2ab\mathbb{E}((X_1 - \mathbb{E}X_1)(X_2 - \mathbb{E}X_2)) \\ &= a^2\text{Var}(X_1) + b^2\text{Var}(X_2) + 2ab\mathbb{E}(X_1X_2 - X_1\mathbb{E}X_2 - (X_2\mathbb{E}X_1 + (\mathbb{E}X_1)(\mathbb{E}X_2))) \\ &= a^2\text{Var}(X_1) + b^2\text{Var}(X_2) + 2ab(\mathbb{E}(X_1X_2) - (\mathbb{E}X_1)(\mathbb{E}X_2) - (\mathbb{E}X_1)(\mathbb{E}X_2) + (\mathbb{E}X_1)(\mathbb{E}X_2)) \\ &= a^2\text{Var}(X_1) + b^2\text{Var}(X_2) + 2ab(\mathbb{E}(X_1X_2) - (\mathbb{E}X_1)(\mathbb{E}X_2)) = a^2\text{Var}(X_1) + b^2\text{Var}(X_2). \end{aligned}$$

## Definición

Dada dos variables aleatorias  $X_1, X_2$  (definidas sobre el mismo espacio). Definimos su **covarianza** como:

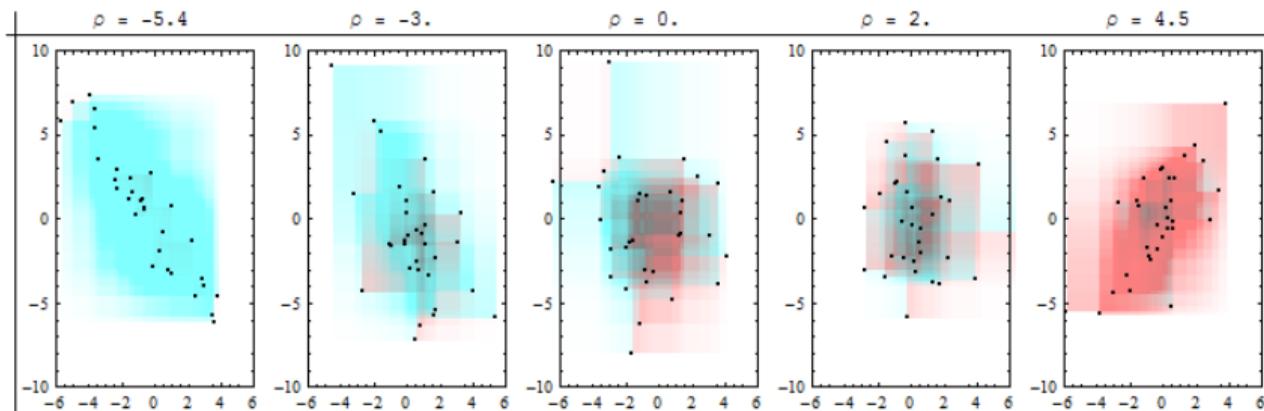
$$\text{Cov}(X_1, X_2) = \mathbb{E}[(X_1 - \mathbb{E}X_1)(X_2 - \mathbb{E}X_2)],$$

en caso de que este valor esperado exista.

## Propiedades:

- $\text{Cov}(X_1, X_2) = \text{Cov}(X_2, X_1)$ .
- $\text{Cov}(aX, bY) = ab\text{Cov}(X, Y)$ .
- $\text{Cov}(aX, X) = a\text{Var}(X)$ .
- Si  $X_1, X_2$  son independientes, entonces  $\text{Cov}(X_1, X_2) = 0$ .

# Covarianza



## Definición

Dada dos variables aleatorias  $X, Y$ , definimos su **correlación** (o **coeficiente de correlación**) como:

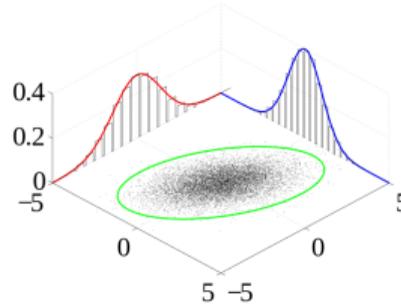
$$\rho(X, Y) = \frac{\text{Cov}(X_1, X_2)}{\sqrt{\text{Var}(X) \text{Var}(Y)}}.$$

### Propiedades:

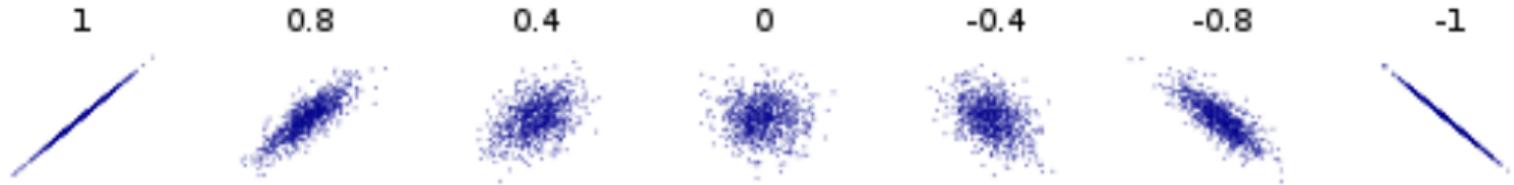
- $\rho(X, Y) = \rho(Y, X)$ .
- $-1 \leq \rho(X, Y) \leq 1$ .
- $\rho(aX, bY) = \rho(X, Y)$ .
- $\rho(aX, X) = \text{sign}(a)$ .
- Si  $X, Y$  son independientes, entonces  $\rho(X, Y) = 0$ .

# Correlación

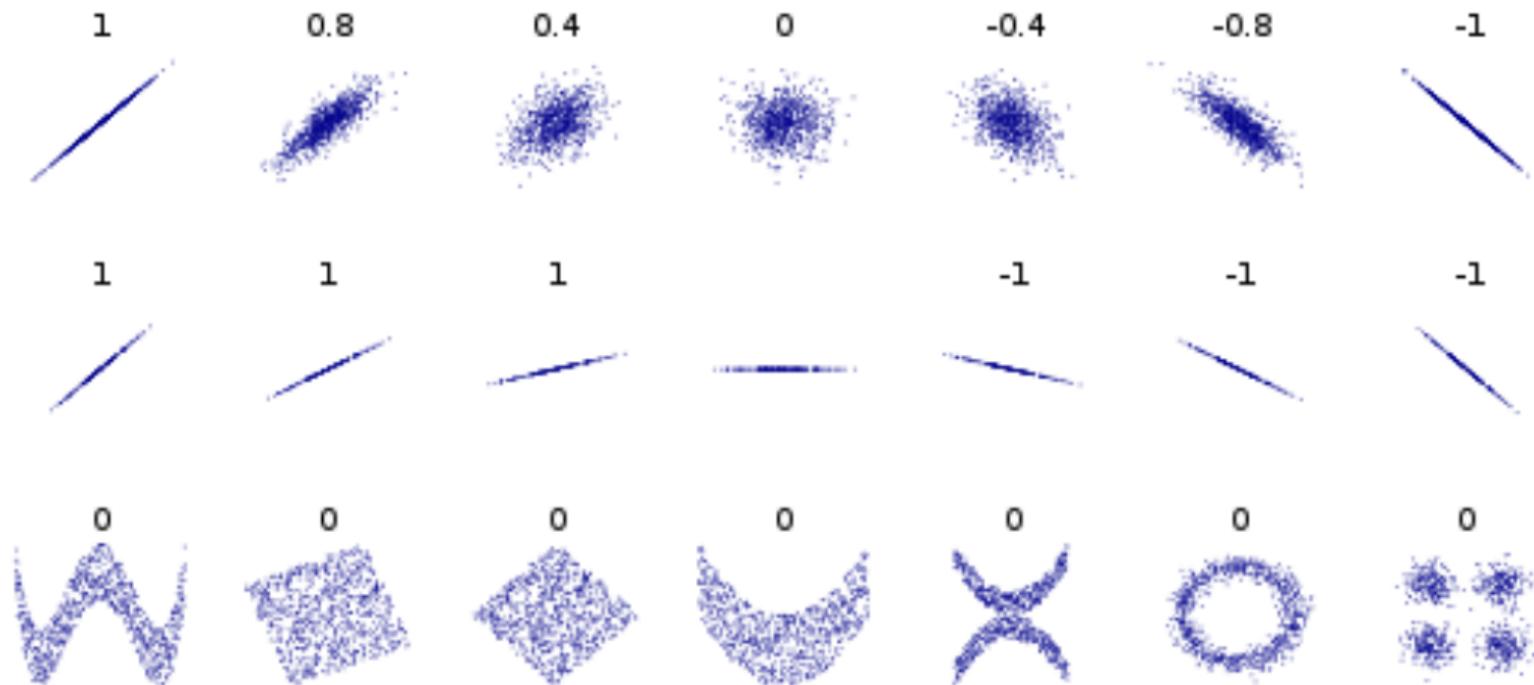
Por ejemplo, para el caso de dos v.a. normales  $X$  y  $Y$ :



tenemos



# Correlación



Ya vimos que la varianza presenta limitaciones (igual que la covarianza).

Punto de partida: medir la sorpresa asociada el evento  $X = x$ ,  $I(x)$ . La entropía es el valor esperado de esta sorpresa  $\mathbb{E}(I(x))$ .

¿Cómo medimos esta sorpresa o incerteza?

- Un evento que ocurre con alta probabilidad no genera sorpresa.
- Un evento que ocurre con baja probabilidad genera mayor sorpresa (más entre menor es  $\mathbb{P}$ ).

¿Cómo definir  $I(x)$ ? Tenemos varias alternativas simples

$$I(x) = \frac{1}{\mathbb{P}(X = x)}, \quad I(x) = 1 - \mathbb{P}(X = x), \quad I(x) = -\log \mathbb{P}(X = x).$$

## Definición

Sea  $X$  una v.a. discreta. Definimos su **entropía de Shannon** como:

$$H(X) = - \sum_x \mathbb{P}(X = x) \log \mathbb{P}(X = x).$$

**Comentario:** Shannon definió la entropía en un contexto de teoría de la información (bits), usa  $\log_2$ . Si  $p = 0$ , usualmente se define  $p \log p = 0$ .

## Definición

Sea  $X$  una v.a. discreta. Definimos su **entropía de Gini** o **coeficiente de Gini** por:

$$G(X) = \sum_x \mathbb{P}(X = x) (1 - \mathbb{P}(X = x)) = 1 - \sum_x \mathbb{P}(X = x)^2.$$

1. Dibuja dos distribuciones o variables aleatorias (discretas) distintas, con mismo promedio y entropía, pero varianzas diferentes.
2. Toma una v.a.  $X \in \{0, 1\}$ . Calcular la varianza y la entropía de Shannon y de Gini en función de  $p = \mathbb{P}(X = 1)$ .  
Compara la gráficas de  $H(X)$  y  $2G(X)$ .
3. ¿Cuáles son los valores mínimo y máximo para  $H(X)$  y  $G(X)$ ?

# Entropía condicional

## Definición

Sean  $X, Y$  dos variables aleatorias, la **entropía condicional** de  $X$  dado  $Y$  es

$$H_Y(X) = \mathbb{E}H(X | Y) = - \sum_y \left( \sum_x \mathbb{P}(X = x | Y = y) \log \mathbb{P}(X = x | Y = y) \right) \mathbb{P}(Y = y).$$

**Obs.** No es simétrica:  $H_Y(X) \neq H_X(Y)$ .

## Definición

Sean  $X, Y$  dos variables aleatorias, la **información mutua** de  $X$  y  $Y$  está dada por

$$I(X, Y) = H(X) - H_Y(X).$$

## Proposición

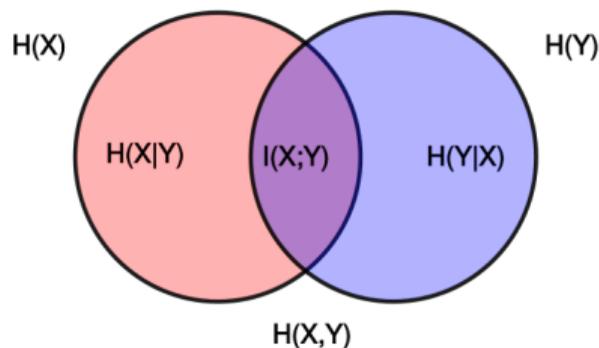
$$I(X, Y) = I(Y, X).$$

# Entropía

## Definición

La **entropía conjunta** de  $X$  y  $Y$  es

$$H(X, Y) = - \sum_x \sum_y \mathbb{P}(x, y) \log \mathbb{P}(x, y).$$



Un diagrama de Venn que muestra relaciones aditivas y sustractivas entre varias medidas de información asociadas con las variables  $X$  y  $Y$ . El área contenida por ambos círculos es la entropía conjunta  $H(X, Y)$ . El círculo de la izquierda (rojo y violeta) es la entropía individual  $H(X)$ , siendo el rojo la entropía condicional  $H_Y(X)$ . El círculo de la derecha (azul y violeta) es  $H(Y)$ , y el azul es  $H_X(Y)$ . El violeta es la información mutua  $I(X, Y)$ .

## Definición

Sean  $P$  una distribución discreta de probabilidad, la **entropía** de  $P$  es

$$H(P) = - \sum_x P(x) \log P(x).$$

## Definición

Sean  $P, Q$  dos distribuciones discretas de probabilidad, la **entropía cruzada** (cross-entropy) de  $P$  y  $Q$  es

$$H(P, Q) = - \sum_x P(x) \log Q(x).$$

Además, la **divergencia de Kullback-Leibler** de  $P$  y  $Q$  se define como

$$\begin{aligned} D_{KL}(P \parallel Q) &= - \sum_x P(x) \log \frac{Q(x)}{P(x)} \\ &= - \sum_x P(x) \log Q(x) + \sum_x P(x) \log P(x) = H(P, Q) - H(P). \end{aligned}$$