



2 Repaso de Variables Aleatorias y Funciones de Distribución

2.1 Conceptos familiares.

El objetivo es presentar un breve repaso de las nociones de probabilidad, necesarias para iniciar el estudio de procesos estocásticos.

Una variable aleatoria (v.a.) X es llamada **discreta** si hay un conjunto de valores distintos, finito o numerable x_1, x_2, \dots , tales que $p_i = P\{X = x_i\} > 0$, $i = 1, 2, 3, \dots$, y $\sum_i p_i = 1$. Si $P\{X = x\} = 0$ para cada valor de x , la variable aleatoria es llamada **continua**.

Si hay una función no negativa $f(t)$, definida para $-\infty < t < \infty$ tal que la **función de distribución** F sobre la variable aleatoria X es dada por

$$F(x) = \int_{-\infty}^x f(t) dt$$

entonces se dice que f es la **densidad de probabilidad** de X . Si X tiene una densidad de probabilidad, entonces necesariamente es continua, pero hay ejemplos de variables aleatorias las cuales no poseen densidades de probabilidad (**Tarea**. Buscar ejemplos de variables aleatorias que no posean densidad de probabilidad).

La cantidad $E[X^n]$, $n \geq 1$, es llamada el **n -ésimo momento** de X . Se define como:

$$E[X^n] = \begin{cases} \sum_{x:p(x)>0} x^n p_X(x) & \text{si } X \text{ es discreta} \\ \int_{-\infty}^{\infty} x^n f_X(x) dx & \text{si } X \text{ es continua.} \end{cases}$$

El primer momento de X es conocido como la **media**, y es usual denotarla por μ_X . El **m -ésimo momento central** de X se define como el m -ésimo momento de la variable aleatoria $X - \mu_X$ si μ_X existe. El primer momento central es evidentemente cero; el segundo momento



central es llamado la **varianza** σ_X^2 de X . La **mediana** de una variable aleatoria X es cualquier m con la propiedad de que $P\{X \geq m\} \geq 1/2$ y $P\{X \leq m\} \geq 1/2$.

Si X es una variable aleatoria y g es una función, entonces $Y = g(X)$ es también una variable aleatoria. Su valor esperado está dado por

$$E[g(X)] = \begin{cases} \sum_{i=1}^{\infty} g(x_i) P\{X = x_i\}, & \text{si } g(X) \text{ es discreta} \\ \int g(x) f_X(x) dx, & \text{si } g(X) \text{ es continua.} \end{cases}$$

2.2 Funciones de distribución conjunta.

Dado un par (X, Y) de variables aleatorias, su **función de distribución conjunta** es la función F_{XY} de dos variables reales dadas por

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

La función $F(x, +\infty) \equiv \lim_{y \rightarrow \infty} F(x, y)$ es una función de distribución de probabilidad llamada la **función de distribución marginal de X** . De manera similar, la función $F(+\infty, y)$ es llamada la **distribución marginal de Y** . Si sucede que $F(x, +\infty) \cdot F(+\infty, y) = F(x, y)$ para cada elección de x, y , entonces las variables aleatorias X y Y son independientes. Una función de distribución conjunta F_{XY} se dice que posee una densidad de probabilidad conjunta si existe una función $f_{XY}(s, t)$ de dos variables reales tal que

$$F_{XY}(x, y) = \int_{-\infty}^y \int_{-\infty}^x f_{XY}(s, t) ds dt$$

para todo x, y . Si X y Y son independientes, entonces $f_{XY}(s, t)$ es necesariamente de la forma $f_X(s) \cdot f_Y(t)$, donde f_X y f_Y son las densidades de probabilidad de la distribución marginal de X y Y , respectivamente.

La función de distribución conjunta de cualquier colección finita X_1, \dots, X_n de variables aleatorias es definida como la función

$$\begin{aligned} F(x_1, \dots, x_n) &= F_{X_1, \dots, X_n}(x_1, \dots, x_n) \\ &= P\{X_1 \leq x_1, \dots, X_n \leq x_n\} \end{aligned}$$



La función de distribución

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = \lim_{x_i \rightarrow \infty, i \neq i_1, \dots, i_k} F(x_1, \dots, x_n)$$

es llamada la distribución marginal de las variables aleatorias X_{i_1}, \dots, X_{i_k} . Si $F(x_1, \dots, x_n) = F_{X_1}(x_1) \cdot \dots \cdot F_{X_n}(x_n)$ para todos los valores de x_1, \dots, x_n , las variables aleatorias X_1, \dots, X_n se dice que son independientes.

Una función de distribución conjunta $F(x_1, \dots, x_n)$ se dice que tiene una densidad de probabilidad si existe una función no negativa $f(t_1, \dots, t_n)$ de n variables tal que

$$F(x_1, \dots, x_n) = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_1} f(t_1, \dots, t_n) dt_1 \dots dt_n$$

para todo real x_1, \dots, x_n .

Si X y Y son variables aleatorias distribuidas conjuntamente teniendo medias μ_X y μ_Y , respectivamente, su **covarianza** σ_{XY} es el momento producto

$$\sigma_{XY} = E[(X - \mu_X)(Y - \mu_Y)].$$

Si X_1 y X_2 son variables aleatorias independientes teniendo las funciones de distribución F_1 y F_2 , respectivamente, entonces la función de distribución F de la suma $X = X_1 + X_2$ es la **convolución** de F_1 y F_2 :

$$F(x) = \int F_1(x - y) dF_2(y) = \int F_2(x - y) dF_1(y).$$

Especializándose a la situación donde X_1 y X_2 tienen las densidades de probabilidad f_1 y f_2 , la función de densidad f de la suma $X = X_1 + X_2$ es la **convolución** de las densidades f_1 y f_2 :

$$f(x) = \int f_1(x - y) df_2(y) = \int f_2(x - y) df_1(y).$$

2.3 Distribuciones condicionales y esperanzas condicionales.

La **probabilidad condicional** $P\{A|B\}$ del evento A dado el evento B es definido por



$$P\{A|B\} = \frac{P\{A \text{ y } B\}}{P\{B\}}, \text{ si } P\{B\} > 0,$$

y es indefinida a la izquierda, o asignado un valor arbitrario, cuando $P\{B\} = 0$.

Sean X y Y variables aleatorias las cuales pueden obtener sólo una infinidad de valores numerables, digamos 1, 2, La **función de distribución condicional** $F_{X/Y}(\cdot/y)$ de X dado $Y = y$ se define por

$$F_{X/Y}(\cdot|y) = \frac{P\{X \leq x, Y = y\}}{P\{Y = y\}}, \text{ si } P\{Y = y\} > 0,$$

Supongamos ahora que X y Y son variables aleatorias continuas distribuidas conjuntamente teniendo la función de densidad de probabilidad conjunta $f_{XY}(x,y)$. Entonces la **distribución condicional** de X dado $Y = y$ es dada por

$$F_{X|Y}(x|y) = \frac{\int_{t \leq x} f_{XY}(t,y) dt}{f_Y(y)}, \text{ siempre que } f_Y(y) > 0.$$

$F_{X/Y}(x/y)$ satisface:

- i. $F_{X/Y}(x/y)$ es una función de distribución de probabilidad en x para cada y fijo.
- ii. $F_{X/Y}(x/y)$ es una función de y para cada x fija; y
- iii. Para cualesquiera valores x, y

$$P\{X \leq x, Y \leq y\} = \int_{\eta \leq y} F_{X|Y}(x|\eta) dF_Y(\eta)$$

Donde $F_Y(\eta) = P\{Y \leq \eta\}$ es la distribución marginal de Y .

Cuando Y es una variable aleatoria continua que tiene la función de densidad de probabilidad $f_Y(y)$, la integral definida en el último punto es calculada como

$$P\{X \leq x, Y \leq y\} = \int_{\eta \leq y} F_{X|Y}(x|\eta) f_Y(\eta) d\eta.$$

Y cuando Y es discreta, la fórmula es

$$P\{X \leq x, Y \leq y\} = \sum_{\eta \leq y} F_{X|Y}(x|\eta) P\{Y = \eta\}.$$



Esas tres propiedades (i-iii) capturan la característica esencial de las distribuciones condicionales. De hecho, a partir del tercer punto obtenemos

$$\begin{aligned} P\{X \leq x, Y = y\} &= P\{X \leq x, Y \leq y\} - P\{X \leq x, Y < y\} \\ &= \sum_{\eta \leq y} F_{X|Y}(x | \eta) P\{Y = \eta\} - \sum_{\eta < y} F_{X|Y}(x | \eta) P\{Y = \eta\} \\ &= F_{X|Y}(x | y) P\{Y = y\} \end{aligned}$$

lo cual entonces implica la definición $F_{X|Y}(x | y) = P\{X \leq x, Y \leq y\} / P\{Y = y\}$, en donde $P\{Y = y\} > 0$. de igual modo, esas tres propiedades son tomadas como la base para la definición de las distribuciones condicionales.

La aplicación de (iii) en el caso $y = \infty$ produce la **Ley de Probabilidad Total**

$$P\{X \leq x\} = P\{X \leq x, Y < \infty\} = \int_{-\infty}^{+\infty} F_{X|Y}(x | y) dF_Y(y),$$

la cual es una de las fórmulas más fundamentales del análisis de probabilidad.

Cuando Y es discreta esta relación es

$$P\{X \leq x\} = \sum_y P\{X \leq x | Y = y\} P\{Y = y\}.$$

Cuando Y tiene función de densidad de probabilidad $f_Y(y)$ se tiene

$$P\{X \leq x\} = \int_{-\infty}^{+\infty} P\{X \leq x | Y = y\} f_Y(y) dy.$$

Cuando X y Y son variables aleatorias continuas distribuidas conjuntamente, podemos definir la **función de densidad condicional** $f_{X|Y}(x | y)$ de X dado que Y = y por

$$f_{X|Y}(x | y) = \frac{d}{dx} F_{X|Y}(x | y) = \frac{f_{XY}(x, y)}{f_Y(y)}$$

en valores de y para los cuales $f_Y(y) > 0$.

Sea g una función para la cual la esperanza de g(X) es finita. La **esperanza condicional** de g(X) dado que Y = y puede ser expresada en la forma



$$E[g(X) | Y = y] = \int_x g(x) dF_{X|Y}(x | y).$$

Cuando X y Y son variables aleatorias continuas conjuntas, $E[g(X)|Y = y]$ puede ser calculada de

$$E[g(X) | Y = y] = \int g(x) f_{X|Y}(x | y) dx$$

$$= \frac{\int g(x) f_{XY}(x, y) dx}{f_Y(y)}, \quad \text{si } f_Y(y) > 0,$$

y si X y Y son variables aleatorias discretas distribuidas conjuntamente, tomando los posibles valores x_1, x_2, \dots , entonces la fórmula se reduce a

$$E[g(X) | Y = y] = \sum_{i=1}^{\infty} g(x_i) P[X = x_i | Y = y]$$

$$= \frac{\sum_{i=1}^{\infty} g(x_i) P\{X = x_i, Y = y\}}{P\{Y = y\}}, \quad \text{si } P\{Y = y\} > 0.$$

En paralelo a las propiedades (i-iii) vemos que la esperanza condicional de $g(X)$ dado $Y = y$ satisface

(E.1) $E[g(X)|Y = y]$ es una función de y para cada función g para la cual $E[|g(X)|] < \infty$; y

(E.2) Para cada función acotada h tenemos

$$E[g(X)h(Y)] = \int E[g(X)|Y = y] h(y) dF_Y(y)$$

donde F_Y es la función de distribución marginal para Y .

El caso especial en (E.2) con $h(y) \equiv 1$ produce la fórmula que expresa la Ley de Probabilidad Total para esperanzas.

$$E[g(X)h(Y)] = \int E[g(X)|Y = y] dF_Y(y),$$

la cual, cuando Y es discreta, se tiene

$$E[g(X)] = \sum_{i=1}^{\infty} E[g(X) | Y = y_i] P\{Y = y_i\},$$

y, cuando Y tiene función de densidad f_Y , será



$$E[g(X)] = \int E[g(X) | Y = y] f_Y(y) dy .$$

Puesto que la esperanza condicional de $g(X)$ dado que $Y = y$ es la esperanza con respecto a la distribución condicional $F_{X|Y}$, la esperanza condicional se comporta en cierta forma igual que las esperanzas ordinarias. En particular, si a_1 y a_2 son números fijos y g_1 y g_2 son funciones dadas para las cuales $E[|g_i(X)|] < \infty$, $i = 1, 2$, entonces

$$E[a_1 g_1(X) + a_2 g_2(X) | Y = y] = a_1 E[g_1(X) | Y = y] + a_2 E[g_2(X) | Y = y]$$

De acuerdo a (E.1), $E[g(X)|Y = y]$ es una función de la variable real y . Si evaluamos esta función en la variable aleatoria Y , obtenemos una variable aleatoria la cual denotamos por $E[g(X)|Y]$. La propiedad básica (E.2) es entonces establecida para cualquier función acotada h de y .

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

Cuando $h(y) = 1$ para todo y , se obtiene la ley de probabilidad total en la forma

$$E[g(X)] = E\{E[g(X)|Y]\}.$$

La siguiente lista resume todas las propiedades de esperanza condicional. Aquí con o sin subíndices, X y Y son variables aleatorias, c es un número real, g es una función para la cual $E[|g(X)|] < \infty$, f es una función acotada y h es una función de dos variables para la cual $E[|h(X, Y)|] < \infty$.

- a) $E[a_1 g_1(X) + a_2 g_2(X) | Y] = a_1 E[g_1(X) | Y] + a_2 E[g_2(X) | Y]$,
- b) $g \geq 0$ implica que $E[g(X)|Y] \geq 0$,
- c) $E[h(X, Y)|Y = y] = E[h(X, y)|Y = y]$,
- d) $E[g(X)|Y] = E[g(X)]$ si X y Y son independientes,
- e) $E[g(X)f(Y)|Y] = f(Y) E[g(X)|Y]$,
- f) $E[g(X)f(Y)] = E\{f(Y) E[g(X)|Y]\}$,
- g) $E[c | Y] = c$, cuando $g \equiv 1$,
- h) $E[f(Y) | Y] = f(Y)$,
- i) $E[g(X)] = E\{E[g(X)|Y]\}$, cuando $f \equiv 1$.



2.4 Teoremas Límites

Sean Z, Z_1, Z_2, \dots variables aleatorias distribuidas conjuntamente.

A. *Convergencia con probabilidad uno.*

Decimos que Z_n converge a Z con probabilidad uno si $P\{\lim_{n \rightarrow \infty} Z_n = Z\} = 1$.

En palabras, $\lim_{n \rightarrow \infty} z_n = z$, para un conjunto de resultados $Z = z, Z_1 = z_1, Z_2 = z_2,$

... teniendo probabilidad total igual a uno.

B. *Convergencia en probabilidad.*

Decimos que Z_n converge a Z en probabilidad si para cada ε positivo

$$\lim_{n \rightarrow \infty} P\{|Z_n - Z| > \varepsilon\} = 0,$$

o recíprocamente, si para cada ε positivo

$$\lim_{n \rightarrow \infty} P\{|Z_n - Z| \leq \varepsilon\} = 1.$$

En palabras, tomando n suficientemente grande, uno puede alcanzar arbitrariamente probabilidades altas de que Z_n sea arbitrariamente cercano a Z .

C. *Convergencia en media cuadrática.*

Decimos que Z_n converge a Z en media cuadrática si

$$\lim_{n \rightarrow \infty} E\left[|Z_n - Z|^2\right] = 0.$$

D. *Convergencia en distribución.*

Sea $F(t) = P\{Z \leq t\}$ y $F_k(t) = P\{Z_k \leq t\}$, $k = 1, 2, \dots$. Decimos que Z_n converge en distribución a Z si el $\lim_{n \rightarrow \infty} F_n(t) = F(t)$

Para toda t para la cual F es continua.

Nota. Puede probarse que si Z_n converge a Z con probabilidad uno, entonces Z_n converge a Z en probabilidad, y que esto implica que Z_n converge a Z en distribución. Así, la convergencia en distribución es la forma más débil de convergencia.



Muchos de los resultados básicos de la teoría de probabilidad están en la forma de teoremas límites y se mencionan unos cuantos aquí.

Sean X_1, X_2, \dots variables aleatorias idénticamente distribuidas e independientes con media finita m . Sea $S_n = X_1 + \dots + X_n$ y sea $\bar{X}_n = S_n/n$ que es la media simple.

Ley de los Grandes Números (Débil). \bar{X}_n converge en probabilidad a m . Es decir, para cada $\varepsilon > 0$

$$\lim P\{|\bar{X}_n - m| > \varepsilon\} = 0.$$

- **Ley de los Grandes Números (Fuerte).** \bar{X}_n converge a m con probabilidad uno. Es decir,

$$P\{\lim_{n \rightarrow \infty} \bar{X}_n = m\} = 1$$

- **Teorema del Limite Central.** Supongamos que cada X_k tiene varianza finita σ^2 . Sea

$$Z_n = \frac{S_n - nm}{\sigma\sqrt{n}} = \frac{1}{\sigma}(\bar{X}_n - m)\sqrt{n},$$

y sea Z una variable aleatoria normalmente distribuida teniendo media cero y varianza uno. Entonces Z_n converge en distribución a Z . Esto es, para todo real a ,

$$\lim_{n \rightarrow \infty} P\{Z_n \leq a\} = \int_{-\infty}^a \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du.$$

- **Lema de Borel- Cantelli.** Sean A_1, A_2, \dots una sucesión infinita de eventos independientes tal que $P(A_1) + P(A_2) + \dots < \infty$ y sea $B_n = A_n \cup A_{n+1} \cup \dots$. Entonces $P(B_1 \cap B_2 \cap \dots) = 0$.