

Combinatoria

Conjuntos

cumplen las propiedades ASOCIATIVA, CONMUTATIVA y DISTRIBUTIVA

$$A \cap B : \text{intersección} \quad A \cap \emptyset = \emptyset \quad A \cap \Omega = A$$

$$A \cup B : \text{unión} \quad A \cup \emptyset = A \quad A \cup \Omega = \Omega$$

$$A \cap (B \cap C) = (A \cap B) \cap C$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

$$A \cup (B \cup C) = (A \cup B) \cup C \quad \overline{A} = \{x | x \notin A\}$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

$$\overline{A \cup B} = \overline{A} \cap \overline{B}$$

$$\overline{A \cap B} = \overline{A} \cup \overline{B}$$

Selecciones

Nociones: $0! = 1, n! = \sqrt{2\pi n} \left(\frac{n}{e}\right)^n$

Ordenado: 1,2 diferente de 2,1 No Ordenado: 1,2 = 2,1

Permutaciones: $P_n = n! = V_n^n \quad PR_n^{\overbrace{n_1+n_2+\dots+n_m=n}^{n_1, n_2, \dots, n_m}} = \frac{n!}{n_1! \dots n_m!}$
 # de maneras de ordenar n objetos.

Combinaciones: $C_m^n = \binom{m}{n} = \frac{m!}{n!(m-n)!} \quad CR_m^n = C_{m+n}^n$
 # de maneras de escoger n objetos no ordenados de un total de m.

Variaciones: $V_m^n = P_n C_m^n = \frac{m!}{(m-n)!} \quad VR_m^n = m^n = mVR_m^{n-1}$
 # maneras de escoger n objetos ordenados de un total de m.

$$P_{\{a,b,c\}} = |\{abc, acb, bac, bca, cab, cba\}| = 6$$

$$PR_3^{2,1} = |\{aab, aba, baa\}| = 3$$

$$V_{\{a,b,c\}}^2 = |\{ab, ac, ba, bc, ca, cb\}| = 6$$

$$VR_{\{a,b,c\}}^2 = |\{aa, ab, ac, ba, bb, bc, ca, cb, cc\}| = 9$$

$$C_{\{a,b,c\}}^2 = |\{ab, ac, bc\}| = 3$$

$$CR_{\{a,b,c\}}^2 = |\{aa, ab, ac, cc, bb, bc\}| = 6$$

Probabilidad

Espacio de probabilidad $P : F \rightarrow [0,1]$

$$P(\Omega) = 1$$

$$P(\emptyset) = 0$$

$$P(A) \geq 0 \forall A \in F$$

$$\text{si } A, B \in F \text{ i } A \cap B = \emptyset \Rightarrow P(A \cup B) = P(A) + P(B)$$

$$P(\overline{A}) = 1 - P(A)$$

$$P(A) \leq 1 \forall A \in F$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

Acontecimientos independientes

A, B son independientes sii $P(A \cap B) = P(A)P(B)$

Probabilidad condicionada

la probabilidad de A condicionando que B se haya verificado.

$$P(B) \neq 0 \Rightarrow P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Teorema de Bayes

$\{A_1, \dots, A_n\}$ =partición de $\Omega, \cup A_k = \Omega, A_i \cap A_j = \emptyset, \forall i \neq j$

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\underbrace{\sum_{k=1}^n P(B|A_k)P(A_k)}_{P(B)}}$$

Teorema de la Probabilidad Total

$\{A_1, \dots, A_n\}$ =partición de $\Omega, \cup A_k = \Omega, A_i \cap A_j = \emptyset, \forall i \neq j$

$$P(B) = \sum_{k=1}^n P(B|A_k)P(A_k)$$

$$\text{si } \Omega = \{A, \overline{A}\} \Rightarrow P(B) = P(B|A)P(A) + P(B|\overline{A})P(\overline{A})$$

Frecuencia relativa

$$\lim_{n \rightarrow \infty} \frac{n_a}{n} = P,$$

Álgebra de acontecimientos

$$F \neq \emptyset$$

$$\text{si } A \in F \Rightarrow \overline{A} \in F$$

$$\text{si } A, B \in F \Rightarrow A \cap B \in F, A \cup B \in F$$

$$0, \Omega \in F$$

P.i.P.E.

Variable Aleatoria

Definición

· Dado (Ω, F) , espacio probabilizable, $X : \Omega \rightarrow \mathbb{R}$ es medible si los antiimágenes de acontecimientos son acontecimientos.

· Una **variable aleatoria** es una aplicación $X : \Omega \rightarrow \mathbb{R}$ medible. Consiste en asignar valores reales a los resultados de un experimento.

Función distribución

$$F_X(x) = P(X \leq x), 1 - F_X(x) = P(X > x)$$

$$P(a < X \leq b) = F_X(b) - F_X(a)$$

propiedades:

$$0 \leq F_X(x) \leq 1 \quad \lim_{x \rightarrow -\infty} F_X(x) = 0$$

$$\frac{\partial}{\partial x} F_X(x) \geq 0 \quad \lim_{x \rightarrow \infty} F_X(x) = 1$$

Es una función continua por la derecha.
Las discontinuidades indican el carácter discreto.

v.a. Discretas

$$F_X(x) = \sum_k (P_K \cdot u(x - x_k)) \quad P_X(x_k) = F_X(x_k) - F_X(x_{k-1})$$

Bernouilli: $\Omega = \{0, 1\}, P_X(1) = p, P_X(0) = q = 1 - p$
"1:A se verifica, 0:A no se verifica": $p(A)=p$

Binomial: $\Omega = \{0, 1, \dots, n\}, P_X(k) = \binom{n}{k} p^k q^{n-k} = P(x = k)$
Repetimos n veces un experimento de Bernouilli.
X es el # de "1" que obtenemos.


Geométrica:

$$\Omega = \{1, 2, \dots, n\}, P_X(n) = q^{n-1} p, F_X(x) = 1 - q^n$$

X es el # de veces que hemos hecho el experimento


por Jesús Sanz Marcos

hasta que obtenemos un "1".



Hipergeométrica: $\Omega = \{0, 1, \dots, n\}, P_X(k)$

Una urna con b bolas blancas y N-b bol
Sacamos n. X es el # de bolas blancas q



Poisson: $\Omega = \{0, 1, 2, \dots\}, P_X(k) = e^{-\lambda} \frac{\lambda^k}{k!}$
 $P_X(k) = \binom{n}{k} p^k (1-p)^{n-k} \stackrel{n \uparrow}{\approx} e^{-\lambda T} \frac{(\lambda T)^k}{k!}, p = \frac{\lambda T}{n}$

X es el # de veces que se produce un acontecimiento en un intervalo p. Cuando n es grande se produce esta relación entre la binomial y Poisson.

Función densidad

$$f_X \geq 0$$

$$P(a \leq X \leq b) = \int_a^b f_X(x) dx$$

$$f_X(x) = \frac{d}{dx} F_X(x) \text{ por la derecha}$$


$$F_X(x) = \int_{-\infty}^x f_X(\tau) d\tau$$

$$1 = \int_{-\infty}^{\infty} f_X(x) dx$$


v.a. Continuas

$$\Omega = [a, b]$$

Uniforme: $F_X(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & x \geq b \end{cases}$



$f_X(x) = \begin{cases} \frac{1}{b-a}, & a \leq x \leq b \\ 0, & \text{else} \end{cases}$



$$\Omega = \{0, \infty\}, \lambda > 0$$


Exponencial: $F_x = u(x)(1 - e^{-\lambda x})$

$$f_x = u(x)\lambda e^{-\lambda x}$$

Propiedad sin memoria: $P(x > t + h | x > t) = P(X > h)$

$$\Omega = \{-\infty, \infty\}$$

$$F_X(x) = \frac{1}{2} \operatorname{erf}\left(\frac{x-m}{\sqrt{2} \sigma}\right)$$




Gaussiana: $f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}$

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt$$

$$\Omega = \{-\infty, \infty\}, a > 0$$

Cauchy: $F_X(x) = \frac{1}{2} + \frac{1}{\pi} \arctan \frac{x}{a}$

$$f_x = \frac{a/\pi}{x^2 + a^2}$$



Teorema de DeMoivre-LaPlace

$$\text{si } npq \gg 1 \Rightarrow \binom{n}{k} p^k q^{n-k} \approx \underbrace{\frac{1}{\sqrt{2\pi npq}} e^{-\frac{(k-np)^2}{2npq}}}_{\text{Gaussiana } \frac{m=np}{\sigma^2=npq}}, n > 1$$

P.i.P.E.


Función de densidad i distribución condicionadas

$$F_{X|B}(x) = P(X \leq x|B) = \frac{P(X \leq x \cap B)}{P(B)}$$

$$f_{X|B}(x) = \frac{f_X(x)P(B|x=x)}{\int_{-\infty}^{\infty} f(x')P(B|x=x')dx'}$$

si $B = \{a < X \leq b\}$

$$F_X(x) = \begin{cases} 0, & x \leq a \\ \frac{F_X(x) - F_X(a)}{F_X(b) - F_X(a)}, & a < b \leq b \\ 1, & x > b \end{cases}$$



por Jesús Sanz Marcos

Tema V. Dos variables aleatorias

Función de distribución conjunta

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

Propiedades:

$$F_X(x) = F_{XY}(x, \infty)$$

$$F_Y(y) = F_{XY}(\infty, y)$$

$$F_{XY}(\infty, \infty) = 1$$

$$F_{XY}(x, -\infty) = 0$$

$$F_{XY}(-\infty, y) = 0$$

$$\frac{\partial F_{XY}}{\partial x} \geq 0, \frac{\partial F_{XY}}{\partial y} \geq 0,$$

$$P\{x_1 < X \leq x_2, y_1 < Y \leq y_2\} =$$

$$F_{XY}(x_2, y_2) + F_{XY}(x_1, y_1) - F_{XY}(x_1, y_2) - F_{XY}(x_2, y_1)$$

Funcion de densidad conjunta

$$f_{XY}(x, y) = \frac{\partial^2 F_{XY}(x, y)}{\partial x \partial y}$$

Propiedades:

$$\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) dx dy = 1$$

$$f(x, y) \geq 0$$

$$F_{XY}(x, y) = \int_{-\infty}^y \int_{-\infty}^x f(x', y') dx' dy'$$

$$P\{x < X \leq x + dx, Y \leq y\} = \frac{\partial F_{XY}(x, y)}{\partial x} dx$$

$$P\{x < X, y < Y \leq y + dy\} = \frac{\partial F_{XY}(x, y)}{\partial y} dy$$

$$P\{(X, Y) \in D\} = \iint_D f(x, y) dx dy$$

Teorema de existencia

Si una función F(x,y) es tal que:

$$F(-\infty, y) = F(x, -\infty) = 0$$

$$F(\infty, -\infty) = 0$$

$$F_{XY}(x_2, y_2) + F_{XY}(x_1, y_1) - F_{XY}(x_1, y_2) - F_{XY}(x_2, y_1) \geq 0$$

$$\forall x_1 < x_2, y_1 < y_2$$

entonces se pueden hallar dos v.a. X,Y tales que F(x,y) es su función de distribución conjunta.

Relaciones entre función marginal y conjunta

$$F_{XY}(x, y) = \int_{-\infty}^y \int_{-\infty}^x f(x', y') dx' dy'$$

$$f_{XY}(x, y) = \frac{\partial^2 F_{XY}(x, y)}{\partial x \partial y}$$

$$F_X(x) = F_{XY}(x, \infty) = \int_{-\infty}^{+\infty} \int_{-\infty}^x f(x', y') dx' dy'$$

$$F_Y(y) = F_{XY}(\infty, y) = \int_{-\infty}^y \int_{-\infty}^{+\infty} f(x', y') dx' dy'$$

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

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

Masas puntuales (Las dos discretas)

$$P\{X = x_k, Y = y_n\} = p_{kn}$$

$$P\{X = x_k\} = \sum_n P\{X = x_k, Y = y_n\} = \sum_n p_{kn}$$

$$P\{Y = y_n\} = \sum_k P\{X = x_k, Y = y_n\} = \sum_k p_{kn}$$

$$\sum_k \sum_n p_{kn} = 1$$

Masas lineales

Cuando una de las v.a. es continua y la otra discreta:

X discreta, Y continua : masas verticales
 X continua, Y discreta : masas horizontales

Cuando una de las v.a. es función de la otra: y=G(X)

Independencia de las v.a.

X, Y son independientes si para todo A, B de borelianos de R,

$$P\{X \in A, Y \in B\} = P(X \in A)P(Y \in B)$$

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

Distribución y densidad condicionadas

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

$$F_X(x|y) = \frac{\int_{-\infty}^x f_{XY}(x', y) dx'}{f_Y(y)}$$

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

Esperanza condicionada

$$E[X|y] = \int_{-\infty}^{+\infty} x f_X(x|y) dx = \int_{-\infty}^{+\infty} x \frac{f_{XY}(x, y)}{f_Y(y)} dx$$

$$E[X] = \int_{-\infty}^{+\infty} E[X|y] f_Y(y) dy = E[E[X|Y]]$$

Algunas distribuciones usuales

Uniforme:

$$f_{XY} = \begin{cases} k & \text{si } (x, y) \in D \\ 0 & \text{else} \end{cases}, \text{ on } \frac{1}{k} = \int_D f_{xy}(x, y) dx dy = \text{area}(D)$$

Normal bidimensional:

$$f_{XY}(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-r^2}} e^{-\frac{1}{2(1-r^2)}\left[\frac{(x-\mu_x)^2}{\sigma_x^2} + \frac{(y-\mu_y)^2}{\sigma_y^2} - \frac{2r(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y}\right]}$$

· X, Y conjuntamente normales, entonces son marginalmente normales:

$$f_X(x) = \frac{1}{\sigma_x\sqrt{2\pi}} e^{-\frac{(x-\mu_x)^2}{2\sigma_x^2}}, f_Y(y) = \frac{1}{\sigma_y\sqrt{2\pi}} e^{-\frac{(y-\mu_y)^2}{2\sigma_y^2}}$$

· X, Y normales e independientes -> conjuntamente normales (r=0)

Tema VI. Funciones de variables aleatorias bidimensionales

$$Z = g(X, Y)$$

$$\phi_Z = \{(x, y) \in \mathbb{R}^2 | g(x, y) \leq z\}$$

$$F_Z(z) = P\{Z \leq z\} = \int_{\phi_Z} f_{XY}(x, y) dx dy$$

$$f_Z(z) = \frac{dF_Z(z)}{dz}$$

Suma de variables aleatorias. Teorema de convolución

$$Z = X + Y$$

$$f_{X+Y} = f_Z = f_X * f_Y$$

$$P_Z(z_i) = \sum_{g(x_k, y_l) = z_i} p(x_k, y_l)$$

Suma de variables de poisson independientes

$$P_Z\{n\} = \sum_{k+l=n} e^{-a_1} \frac{a_1^k}{k!} e^{-a_2} \frac{a_2^l}{l!} = e^{-(a_1+a_2)} \frac{(a_1+a_2)^n}{n!}$$

Suma de variables normales independientes

$$f_X(x) = \frac{1}{\sigma_x\sqrt{2\pi}} e^{-\frac{(x-\mu_x)^2}{2\sigma_x^2}}, f_Y(y) = \frac{1}{\sigma_y\sqrt{2\pi}} e^{-\frac{(y-\mu_y)^2}{2\sigma_y^2}}$$

$$f_{X+Y}(z) = \frac{1}{\sqrt{2\pi(\sigma_x^2+\sigma_y^2)}} e^{-\frac{(z-(\mu_x+\mu_y))^2}{2(\sigma_x^2+\sigma_y^2)}}$$

Cambio de variable

P.i.P.E.

por Jesús Sanz Marcos

$$\begin{aligned} Z &= g(X, Y) \\ T &= h(X, Y) \end{aligned} \quad \frac{\partial(x,y)}{d(z,t)} = \left| \begin{array}{cc} \frac{\partial x}{\partial z} & \frac{\partial x}{\partial t} \\ \frac{\partial y}{\partial z} & \frac{\partial y}{\partial t} \end{array} \right| = \left(\frac{\partial(z,t)}{\partial(x,y)} \right)^{-1}$$

$$\begin{aligned} \mu_{jk} &= E[(X - \bar{X})^k (Y - \bar{Y})^j] = \\ &= \int_{\cdot} (x - \mu_x)^j (y - \mu_y)^k f(x, y) dx dy \end{aligned}$$

$$dx dy = \left| \frac{\partial(x,y)}{\partial(z,t)} \right| dz dt$$

$$f_{ZT}(z, t) = f_{XY}(x(z, t), y(z, t)) \left| \frac{\partial(x,y)}{\partial(z,t)} \right|$$

coordenadas polares:

coordenadas esféricas

$$\begin{aligned} x &= r \cos \theta & x &= r \sin \psi \cos \theta \\ y &= r \sin \theta & y &= r \sin \psi \sin \theta \\ J_{XY} &= r & z &= r \cos \psi \\ & & J_{XYZ} &= r^2 \sin \psi \end{aligned}$$

Ortogonalidad

X, Y ortogonales si $E[XY] = 0 := X \perp Y$

Incorrelación

X, Y incorreladas si: $\rho = 0, C[X, Y] = 0 \sim E[XY] = \bar{X}\bar{Y}$

Tema VII. Parámetros estadísticos

$$Z = g(X, Y)$$

Esperanza

$$E[Z] = E[g(X, Y)] = \int_{\cdot} g(x, y) f(x, y) dx dy$$

Covarianza

$$C[X, Y] = E[(X - \bar{X})(Y - \bar{Y})] = E[XY] - \bar{X}\bar{Y}$$

Coefficiente de correlación

$$\rho = \frac{C[X, Y]}{\sigma_x \sigma_y} \quad |\rho| \leq 1$$

Momentos

$$m_{jk} = E[X^j Y^k] = \int_{\cdot} x^j y^k f(x, y) dx dy$$

Momentos centrales

Estimación de variables aleatorias

Concepto y criterios

Y v.a., repetimos N veces este experimento, obteniendo y_1, y_2, \dots, y_n . Estimar la variable Y significa hacer una predicción que se acerque el máximo a estos resultados.

ε := error

$\bar{\varepsilon}$:= error cuadrático medio

$$\bar{\varepsilon} = E[\varepsilon] = \frac{1}{N} \sum_i E[(Y_i - c_i)^2] = E[(Y - c)^2]$$

Estimación por una constante

Estimamos Y por una constante c. La mejor estimación es

$$c = E[Y] \quad \bar{\varepsilon}_{\min} = V[Y]$$

Estimación no lineal

Estimamos Y por $c(X)$, función a determinar de la v.a. X. La mejor estimación se llama **curva de regresión** y es:

$$c(x) = E[Y|x]$$

Hay dos casos extremos:

· X, Y son independientes.

Entonces: $E[y|x] = E[Y] \Rightarrow c(x) = E[Y] = \dots$

· $Y=g(X)$, es decir, existe la máxima dependencia posible.

$$f(x, y) = f(x)\delta(y - g(x))$$

$$E[Y|x] = g(x) \Rightarrow c(x) = g(x), \bar{\varepsilon}_{\min} = 0$$

Estimación lineal

Estimamos Y por $aX + \beta$

$$a = \rho \frac{\sigma_Y}{\sigma_X}$$

$$\bar{\varepsilon}_{\min} = \sigma_Y^2(1 - \rho^2)$$


$$\beta = m_Y - \rho \frac{\sigma_Y}{\sigma_X} m_X$$

Principio de ortogonalidad

Z, T : v.a

$$: \langle Z, T \rangle = E[ZT], \|Z\| = \langle Z, Z \rangle^{1/2}$$

$$: \bar{\varepsilon}_{\min} = \|Y - c(X)\|^2$$



La mejor estimación es el elemento del hiperplano H más cercano a Y i el error es la distancia entre Y y H.

Sabiendo que $Y - c(X)$ es ortogonal a H.

$$\langle g_i(X), Y - c(x) \rangle = 0, i = 1..n$$

$$E[g_i(X)c(X)] = E[g(X)Y], i = 1..n$$

Introducción a los procesos estocásticos

Procesos estocástico := proceso aleatorio;

"el resultado de un experimento es una función."

$X(t)$: continuo

$X_i = X(t_i)$: discreto

Fijado t, $X(t)$ es una función v.a. unidimensional.

Funciones de distribución de un PE, X(t)

· Las funciones de distribución de orden n son:

$$F(x_1, \dots, x_n; t_1, \dots, t_n) = P(X(t_1) \leq x_1, \dots, X(t_n) \leq x_n)$$

· Las funciones de densidad de orden n son:

$$c = a_1 X_1^{f(x_1, \dots, x_n; t_1, \dots, t_n)} + \dots + a_n X_n^{f(x_1, \dots, x_n; t_1, \dots, t_n)} = \frac{\partial F(x_1, \dots, x_n; t_1, \dots, t_n)}{\partial x_1 \dots \partial x_n}$$

$$c(X) = a_1 g_1(X) + \dots + a_n g_n(X)$$

· El proceso queda totalmente descrito si conocemos todos los valores t_i para todo i. Fijados los valores $t_1..t_n$, tenemos una v.a. n-dimensional.

$$\int_{-\infty}^{+\infty} f(x; t) dx = 1$$

$$\int_{-\infty}^{+\infty} f(x_1, x_2; t_1, t_2) dx_2 = f(x_1; t_1)$$

Valor medio

$$m(t) = E[X(t)] = \int_{-\infty}^{+\infty} x f(x; t)$$

Autocorrelación

$$R(t_1, t_2) = E[X(t_1)X(t_2)] =$$

$$\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_1 x_2 f(x_1, x_2; t_1, t_2) d$$

Autocovarianza

$$C(t_1, t_2) = R(t_1, t_2) - m(t_1)m(t_2)$$

Potencia promedio

$$R(t, t) = E[x(t)^2]$$

Procesos estocásticos normales

P.i.P.E.

por Jesús Sanz Marcos

P.E. X(t), se llama normal si: $\forall n, \forall t_1, \dots, t_n \Rightarrow X(t_1), \dots, X(t_n)$ son conjuntamente normales.

$$f(x_1, \dots, x_n; t_1, \dots, t_n) = \frac{|A|}{(2\pi)^{n/2}} e^{-\frac{1}{2}(x-m)^T A(x-m)}$$

$$A_d = \text{diag}(a_1, \dots, a_n)$$

$$P^{-1} = P^T, A_d = P A P^{-1}, a_i > 0$$

Procesos estacionarios

Un P.E. es estacionario en **sentido estricto**, si su distribución de probabilidad es invariante bajo traslaciones temporales.

$$f(x_1, \dots, x_n; t_1, \dots, t_n) = (x_1, \dots, x_n; t_1 + T, \dots, t_n + T)$$

Un P.E. es estacionario en **sentido amplio**, si su valor medio es constante y su autocorrelación depende sólo de la distancia temporal considerada.

$$m(t) = m, R(t_1, t_2) = R(t_1 - t_2)$$

Un P.E. en sentido amplio también lo es en sentido estricto.

$$\lim_{|T| \rightarrow \infty} C(\tau) = C_{R(0)} \text{ es cte.}$$

Ejemplos de procesos estocásticos

Dado un P.E., si X(t) es discreta entonces el proceso es de estado discreto sino, el proceso es de estado continuo.

El proceso de Poisson

Inicial = 0,

n(t):=# de acontecimientos que se han producido entre [0,T]

n(ta,tb):=n(tb)-n(ta):# de aco. que se han prod. entre [ta,tb]

El # de acontecimientos en dos intervalos temporales disjuntos son v.a. independientes.

$$\text{Si } N = n(t, t + \tau) \Rightarrow P(N = 1) = \lambda\tau + o(\tau), P(N > 1) = o(\tau)$$

$$N = n(t_a, t_b) \Rightarrow P(N = n) = e^{-a} \frac{a^n}{n!},$$


$$a = \lambda(t_b - t_a), n = 0, 1, \dots$$

El P.E. de Poisson consiste en coger como función el # total de acontecimientos producidos en [0,T]

$$P(X(t) = n) = e^{-\lambda t} \frac{(\lambda t)^n}{n!}$$

$$m(t) = \lambda t$$

$$R(t_1, t_2) = \begin{cases} \lambda t_1 + \lambda^2 t_1 t_2 & t_1 \leq t_2 \\ \lambda t_2 + \lambda^2 t_1 t_2 & t_2 \leq t_1 \end{cases}$$



Señal telegráfica aleatorio


n(t) es una variable de Poisson.

El **señal telegráfica semialeatorio** es: $X(t) = \begin{cases} 1 & \text{si } n(t) \text{ es par} \\ -1 & \text{si } n(t) \text{ es impar} \end{cases}$
 $X(0)=1$, y cambia de signo cada vez que se produce un acont.

$$P(x(t) = 1) = P\{n(t) = 0\} + P\{n(t)=2\} + \dots = e^{-\lambda t} \cosh(\lambda t)$$

$$P(x(t) = -1) = P\{n(t) = 1\} + P\{n(t)=3\} + \dots = e^{-\lambda t} \sinh(\lambda t)$$

$$m(t) = e^{-2\lambda t}, R(t_1, t_2) = e^{-2\lambda(t_2-t_1)}$$



El **señal telegráfica aleatorio** es:

S es una v.a. Bernouilli (1,-1), $Y(t)=SX(t)$, con valores equiprobables, independiente de X(t).

$$m(t) = 0, R(t_1, t_2) = e^{-2\lambda(t_2-t_1)}$$

Tren de impulsos de Poisson

si X(t) es un P.E. de Poisson, el tren de impulsos asociado es:

$$Z(t) = \frac{\partial X(t)}{\partial t} = \sum_i \delta(t - t_i) \quad \text{"shot noise"}$$

$$m(t) = \lambda, R(t_1, t_2) = \lambda^2 + \lambda\delta(t_2 - t_1)$$

Distribución del tiempo en el proceso de Poisson

$$f_{T_n}(t) = \lambda \frac{(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t}$$

$$f_{T_1}(t) = \lambda e^{-\lambda t}, T \sim \text{Exp}(\lambda)$$


$$f(t_1, \dots, t_n) = \lambda^n e^{-\lambda t_n}$$

Señales binarios

Si Y(t) es un señal telegráfica aleatorio

$$B(t) = \frac{1 + Y(t)}{2}$$

$$B(t) = B_n \text{ si } nT \leq t < (n+1)T$$



$$X(t) = \cos(\omega t + \theta(t))$$

$$\theta(t) = \begin{cases} \pi/2 & \text{si } B(t)=1 \\ -\pi/2 & \text{si } B(t)=0 \end{cases}$$

$$\omega = 2\pi\nu_p$$

Oscilaciones aleatorias

Se trata de funciones osciladoras que contienen parámetros aleatorios. Ahora estudiaremos cuándo es aleatorio el proceso.

$$X(t) = A \cos \omega t + B \sin \omega t$$

-en sentido amplio sii: $m_A = m_B = 0, \sigma_A = \sigma_B, \rho_{AB} = 0$

-en sentido estricto sii

la distribución de (A,B) tiene simetría circular.

Procesos estacionarios

Integrales estocásticas

Si com resultado del experimento obtenemos $X_1(t)$ decimos que es una realización de est este proceso.

$\lim_{\epsilon \rightarrow 0} f(X(t), \epsilon) = l$ se verifica en media cuadrática (MC) sii
 $\lim_{\epsilon \rightarrow 0} E[(f(X(t), \epsilon^2) - \epsilon^2)] = 0$

$$E[l] = \lim_{\epsilon \rightarrow 0} E[f(X(t), \epsilon)]$$

Si se cumplen (condiciones de continuidad en MC):

$$\lim_{\epsilon \rightarrow 0} E[X(t+\epsilon) - X(t)]^2 = 0$$

$$\lim_{\epsilon \rightarrow 0} \{R(t+\epsilon, t+\epsilon) - 2R(t+\epsilon, t) + R(t, t)\} = 0$$

entonces existe la integral:

$\int_a^b \int_a^b R(t_1, t_2) dt_1 dt_2$, y el proceso es integrable en [a,b]

$\int_a^b X(t) dt$ es v.a.

$$\Rightarrow E[\int_a^b X(t) dt] = \int_a^b E[X(t)] dt$$

Ergodicidad

$$X(t)PE, m(t) = m, R(t, t + \tau) = R(\tau)$$

$$m = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n x_i(t)$$

$$m_T = \langle x(t) \rangle_T = \frac{1}{2T} \int_{-T}^T x(t) dt$$

Un proceso ergódico es aquel en el que los promedios temporales igualan los promedios sobre realizaciones.

Ergodicidad en valor medio:

$$m_T \rightarrow m \text{ en MC. } \propto \lim_{T \rightarrow \infty} E[(m_T - m)^2] = 0$$

$$\sigma_T^2 \rightarrow 0, \text{ cuando } T \rightarrow \infty$$

Ergodicidad en autocorrelación:

$Z_\lambda(t) = X(t + \lambda)X(t)$ es ergódico en valor medio.

$$\sigma_T^2 = \frac{1}{4T^2} \int_{-T}^{+T} \int_{-T}^{+T} C(t_1, t_2) dt_1 dt_2$$

Condiciones suficientes de ergodicidad

$$\text{si } \int_{-\infty}^{+\infty} C(\tau) d\tau < \infty \Rightarrow$$

el proc. es ergódico en va.medio.

$$: |C[x, y]| \leq \sigma_x \sigma_y$$

si $C(0) < \infty$ y $C(\tau) \rightarrow \infty$, cuando $|\tau| \rightarrow \infty$

el proceso es ergódico en valor medio

Espectro de potencia de un proceso estacionario

La densidad espectral o espectro de potencia de un P.E. estacionario es la transformada de Fourier de la función de autocorrelación.

$$S(\omega) = \int_{-\infty}^{+\infty} R(\tau) e^{-j\omega\tau} d\tau$$

$$R(\tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S(\omega) e^{j\omega\tau} d\omega$$

Sistemas lineales

$$Y(t) = L[X(t)] = X(t) * h(t)$$

$$h(t) = L[\delta(t)]$$

- Un sistema es determinista si la realización de $X(t)$ que entra queda determinada a la salida.
- Si por el contrario, una misma entrada puede dar lugar a salidas diferentes, diremos que el proceso es estocástico.

- Un sistema sin memoria es que la salida depende exclusivamente del valor de $X(t)$ para el mismo t.
- Un sistema es lineal si...
- Un sistema es invariante en el tiempo si...

Valor medio, autocorrelación y espectro de potencia de un P.E. transformado linealmente

$$Y(t) = L[X(t)]$$

$$m_Y(t) = L[m_X(t)]$$

$$R_{XY}(t_1, t_2) = E[X(t_1)X(t_2)]$$

$$R_{XY}(t_1, t_2) = L_2[R_{XX}(t_1, t_2)]$$

$$R_{YY}(t_1, t_2) = L_1[R_{XY}(t_1, t_2)]$$

$$H(f) = F\{h(t)\}$$

$$S_{YY}(f) = |H(f)|^2 S_{XX}(f)$$