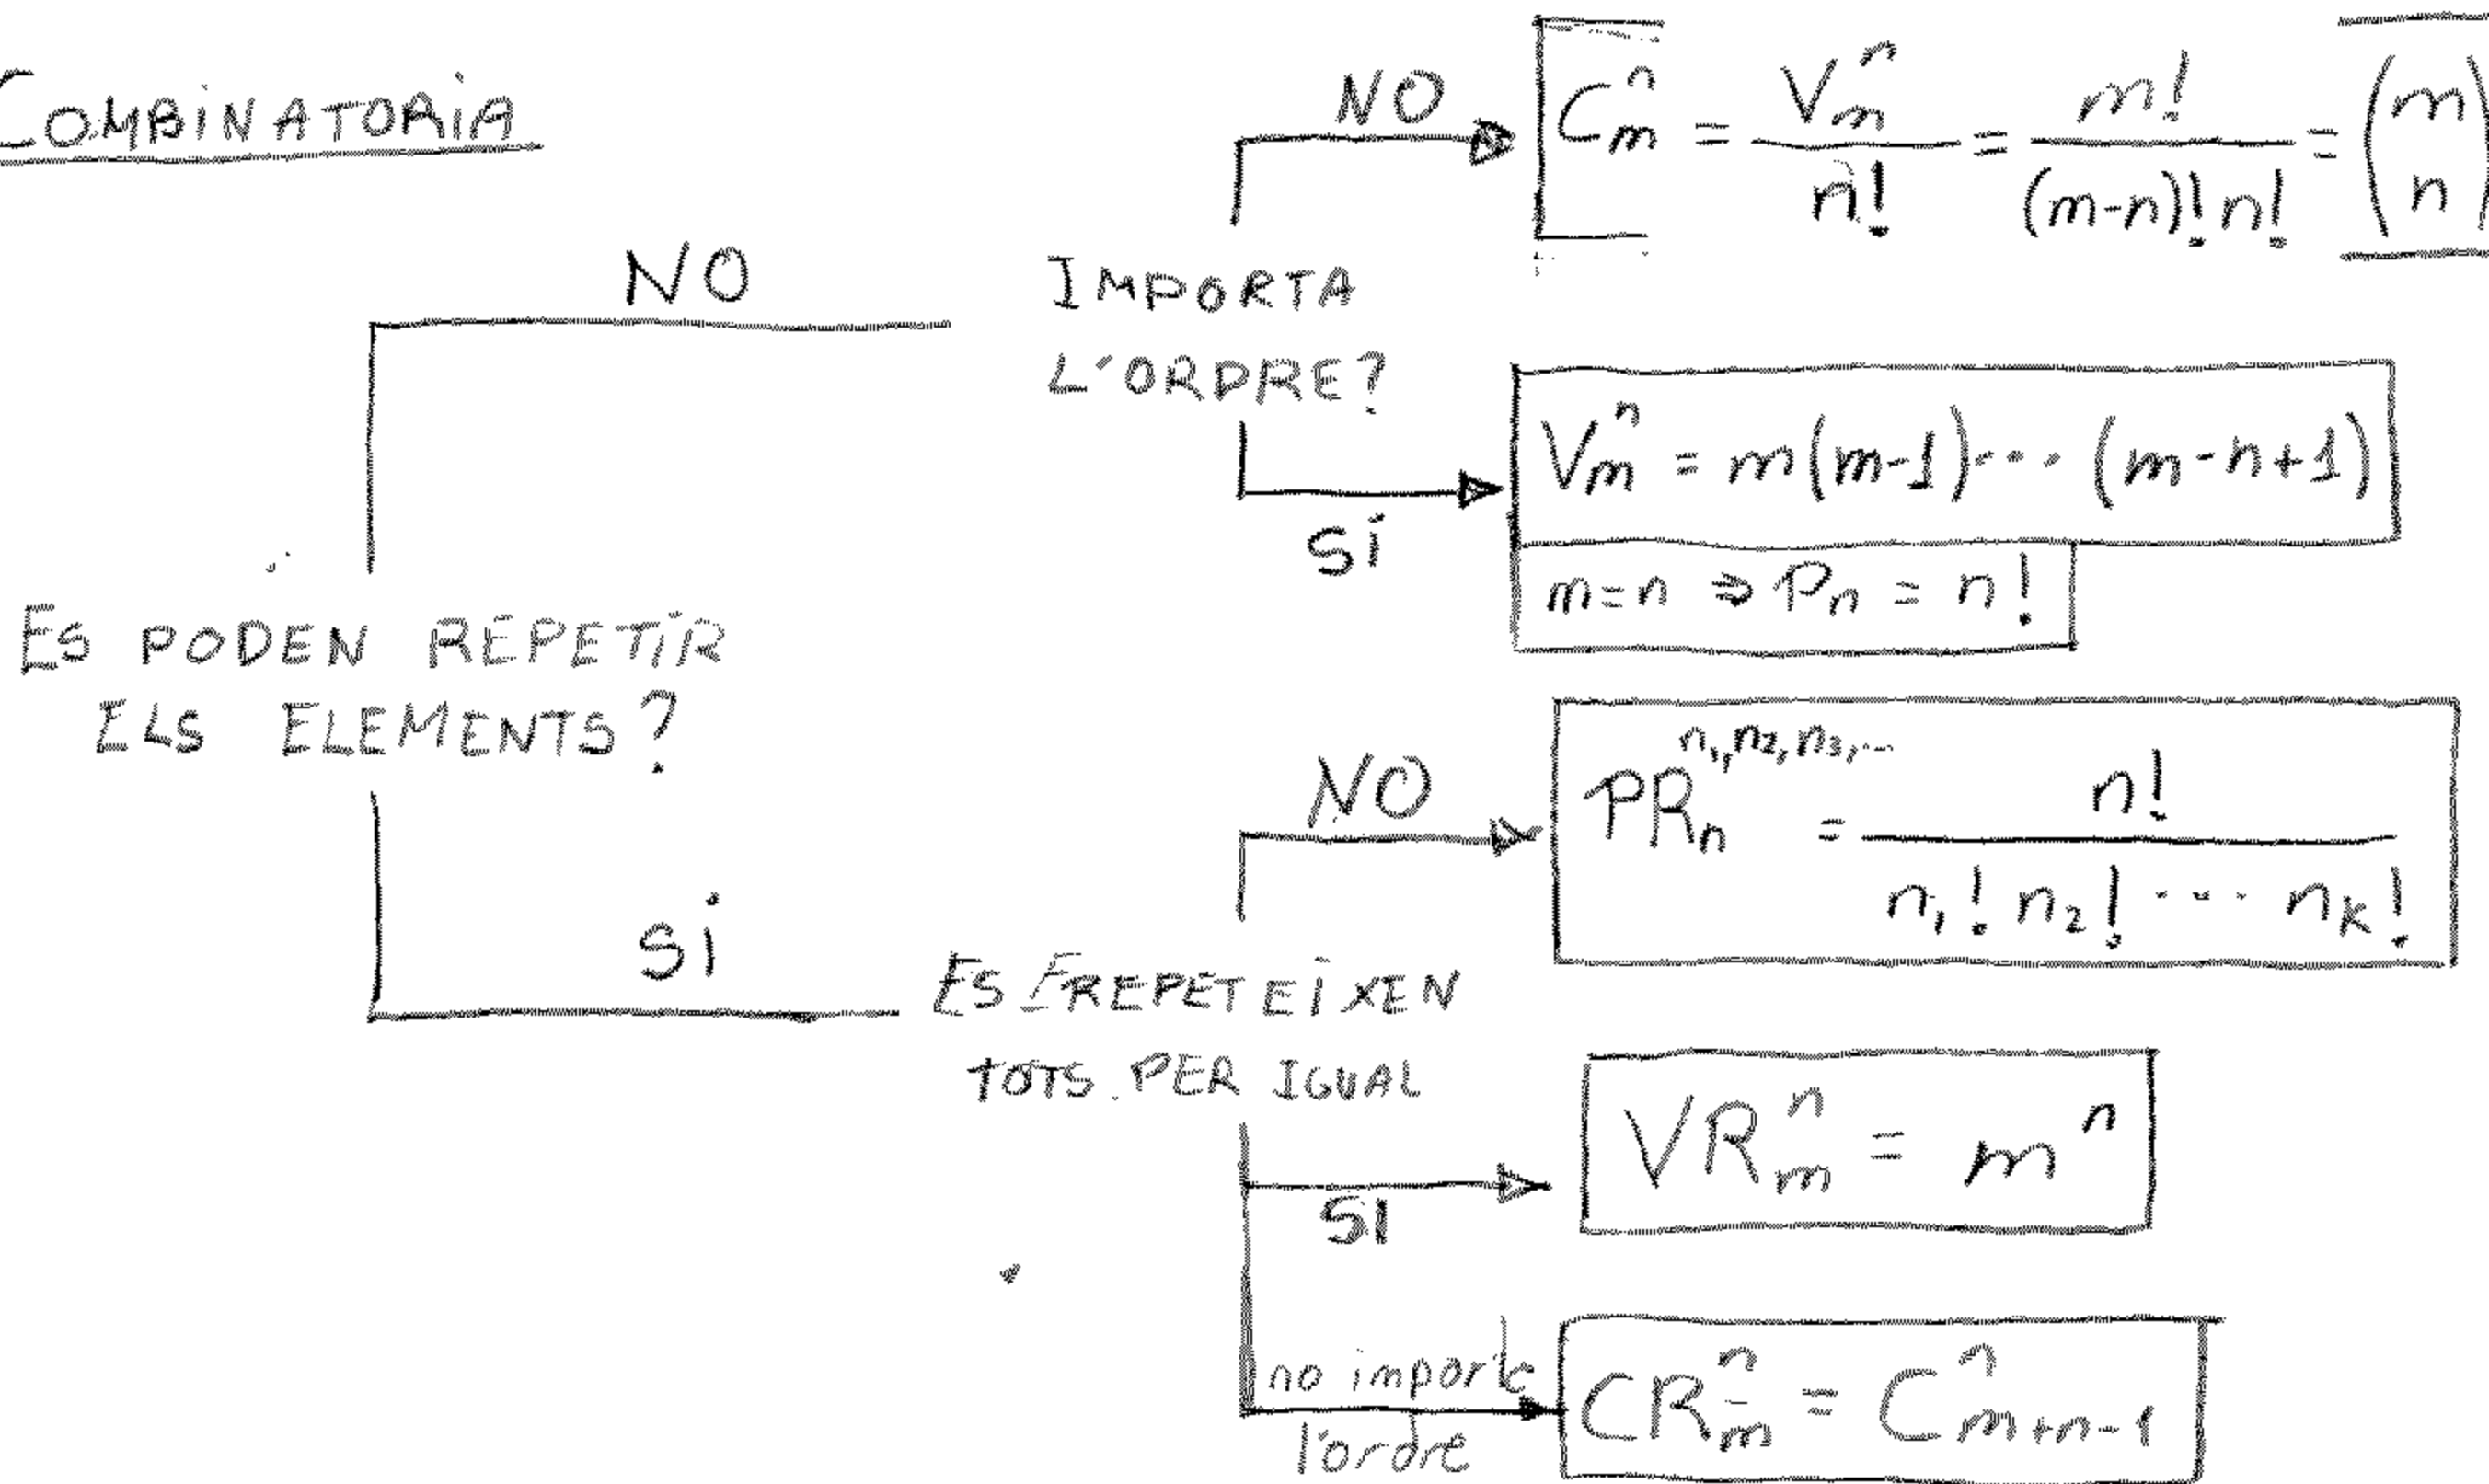


PIPE

TEMA 0: COMBINATORIA



TEMA 1: INTRODUCCIÓ A LA TEORIA DE LA PROBABILITAT

$$P(A) = \frac{\text{casos favorables a } A}{\text{casos possibles}}$$

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

$$P(A_1 \cup A_2 \cup \dots \cup A_n) = \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i \cap A_j) + \dots + (-1)^{n-1} P(A_1 \cap A_2 \cap \dots \cap A_n)$$

* PROBABILITAT CONDICIONADA

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

* ESDEVENIMENTS INDEPENDENTS

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

* TEOR. PROBABILITAT TOTAL
B_i = partició de Ω

$$P(A) = \sum_i P(A|B_i)P(B_i)$$

* FORMULA DE BAYES

$$P(A_i|A) = \frac{P(A|A_i) \cdot P(A_i)}{\sum_k P(A|A_k) \cdot P(A_k)}$$

* PROBABILITAT BINOMIAL

$$P(\tilde{A}) = \binom{n}{r} P(A)^r P(\bar{A})^{n-r}$$

$$(a+b)^n = \sum_{k=0}^n \binom{n}{k} a^k b^{n-k}$$

n → proves
r → casos favorables

TEMA 2: VARIABLES ALEATORIES

- VARIABLES ALEATORIES DISCRETES

$P(X=x_1)=p_1, P(X=x_2)=p_2, \dots$ Funció de prob de X

$$F_X(x) = \sum_{x_k \leq x} p_k$$

* V.A. de Bernemilli

$P(X=0)=q, P(X=1)=p$ Només 2 esdev.

* V.A. Binomial

$$P(X=k) = \binom{n}{k} p^k q^{n-k}$$

* V.A. de Poisson

$$P(X=k) = e^{-m_x} \frac{m_x^k}{k!} \quad k \geq 0$$

Relació
Binomial-Poisson

$$\binom{n}{k} p^k q^{n-k} \xrightarrow[np \rightarrow m_x]{n \rightarrow \infty, p \rightarrow 0} e^{-m_x} \frac{m_x^k}{k!}$$

* V.A. Geomètrica

$$P(X=k) = q^{k-1} p$$

Repetim k vegades l'experiment fins obtenir l'esdeveniment desitjat.

- Llei de prob. multinomial

$$P(A) = \frac{m!}{m_1! m_2! \dots m_r!} p_1^{m_1} p_2^{m_2} \dots p_r^{m_r}$$

Ampliació de la binomial a més de 2 esdeveniments.


- VARIABLES ALEATORIES CONTINUES

Una v.a. és contínua si $F_X(x) \equiv P(X \leq x) = \int_{-\infty}^x f_X(t) dt$

$f_X(x)$ = funció densitat de prob.

* V.A. Uniforme

$$P(x_1 \leq X \leq x_2) = \frac{x_2 - x_1}{b - a}$$



* V.A. Exponencial "de param μ "


$$f_T(t) = \begin{cases} 0 & t < 0 \\ \mu e^{-\mu t} & t \geq 0 \end{cases} \quad F_T(t) = \begin{cases} 0 & t < 0 \\ 1 - e^{-\mu t} & t \geq 0 \end{cases}$$

- Relació Poisson - Exponencial

Si $P(X=k)$ es de Poisson $\Rightarrow P(T \leq t)$ és exponencial

* V.A. Gaussiana "de param m, σ^2 "

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



σ afecta a l'amplada de la campana.

$$\text{erf}(x) = \int_0^x \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$$

$$x = \frac{x_1 - m_x}{\sigma} ; \text{erf}(x) = -\text{erf}(-x)$$

$$P(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2} \left(\frac{x-m_x}{\sigma}\right)^2} dx = \int_{\frac{x_1-m_x}{\sigma}}^{\frac{x_2-m_x}{\sigma}} \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt = \text{erf}\left(\frac{x_2-m_x}{\sigma}\right) - \text{erf}\left(\frac{x_1-m_x}{\sigma}\right)$$

- Relació Binomial - Gaussiana

$$P(X \leq x) = \sum_{k=0}^x \binom{n}{k} p^k q^{n-k} \quad \begin{matrix} m_x \equiv np \\ \sigma \equiv \sqrt{npq} \end{matrix} \quad \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2} \left(\frac{x-m_x}{\sigma}\right)^2}$$

nomes si $np \geq 5$ i $nq \geq 5$

* Funció densitat generalitzada X v.a. discreta

$$f_x(x) = \sum_{i=1}^n p_i \delta(x-x_i)$$

* Funcions de distribució i densitat condicionades

$$F_x(x) \equiv P(X \leq x) \Rightarrow F_x(x|B) = P(X \leq x | B)$$

$$P(A|X=x) = \frac{f_x(x|A)P(A)}{f_x(x)}$$


si x és un punt on $f_x(x) \neq 0$

* TEOREMA DE LA PROBABILITAT TOTAL I FÓRMULA DE BAYES (v.a. contínua)

$$P(A) = \int_{-\infty}^{\infty} P(A|X=x) f_x(x) dx$$

$$f_x(x|A) = \frac{P(A|X=x) f_x(x)}{\int_{-\infty}^{\infty} P(A|X=t) f_x(t) dt}$$

TEMA 3: FUNCIONS D'UNA V.A.



- Cas $g(x)$ continua i creixent

$$\boxed{F_Y(y) = F_X(h(y))}$$

- " decreixent

$$\boxed{F_Y(y) = 1 - F_X(h(y)) + P(X=h(y))}$$

0 va cont

- Cas general, $g(x)$ continua a trossos

$$\boxed{f_Y(y) = \sum_i \frac{f_X(x_i)}{|g'(x)|_{x=x_i}}$$

Si no te solució: $f_Y(y) = 0$

solucions $y=g(x_i)$ } x_i en funció de y

TEMA 4: PARÀMETRES ESTADÍSTICS

- X v.a. discreta (pren valors x_i amb prob p_i)

$$\boxed{m_x \equiv E(X) = \sum_i x_i p_i}$$

$$\boxed{\sigma_x^2 \equiv \text{Var}(X) = \sum_i (x_i - m_x)^2 p_i}$$

- X v.a. continua amb densitat de prob. $f_X(x)$

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

$$\boxed{\sigma_x^2 = \int_{-\infty}^{\infty} (x - m_x)^2 f_X(x) dx}$$

m_x : Esperança σ_x^2 : Variància σ_x : desviació típica

v.a	Uniforme	Indicativ	Binomial	Geometric	Gaussiana	Poisson	Exponencial
$E(X) = m_x$	$\frac{a+b}{2}$	p	mp	$1/p$	m	λ	$1/\mu$
$\text{Var}(X) = \sigma_x^2$	$\frac{(b-a)^2}{12}$	$p^2q + q^2p$	mpq	q/p^2	σ^2	λ	$1/\mu^2$

* En general, $\{A_1, A_2, \dots, A_n\}$ partició de Ω

$$E(X) = \sum_{k=1}^n E(X|A_k) P(A_k) \quad E(X|A_k) = \begin{cases} \sum x_i P(X=x_i|A_k) \\ \int_{-\infty}^{\infty} x f_x(x|A_k) dx \end{cases}$$

* EL TEOREMA DE L'ESPERANÇA

$$E(Y) = E(g(X)) = \begin{cases} \sum_k g(x_k) P(X=x_k) & \text{v.a. discret} \\ \int_{-\infty}^{\infty} g(x) f_x(x) dx & \text{v.a. continu} \end{cases}$$

$$* \text{Var}(X) = E((X - m_x)^2) = E(X^2) - (E(X))^2$$

* DESIGUALTAT DE CHEBYSHEV

$$P\{|X - m_x| \geq \varepsilon\} \leq \frac{\sigma_x^2}{\varepsilon^2}$$

Prob. $m_x - \varepsilon < X < m_x + \varepsilon$ de que la v.a. es trobi entre uns valors concrets

* Moments i moments centrats

$$m_n = E(X^n)$$

$$\mu_n = E((X - m_x)^n) \quad \mu_2 = \sigma^2$$

TEMA 5: V.A. BIDIMENSIONAL

* FUNCIO DISTRIBUCIO

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

PROPIETATS:

$$F_{XY}(x, \infty) = F_X(x) \quad \text{idem } y$$

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

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

continu

$$F_{XY}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{XY}(u, v) du dv$$

discret

$$F_{XY}(x, y) = \sum_{x_i \leq x} \sum_{y_j \leq y} P_{XY}(x_i, y_j)$$

$$P\{x_1 < X \leq x_2, y_1 < Y \leq y_2\} = F_{XY}(x_2, y_2) - F_{XY}(x_1, y_2) - F_{XY}(x_2, y_1) + F_{XY}(x_1, y_1)$$

$$= \int_{x_1}^{x_2} \int_{y_1}^{y_2} f_{XY}(u, v) du dv$$

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

FUNCIO DENSITAT

* FUNCIONS DISTRIBUCIO I DENSITAT MARGINALS

$$F_X(x) = \int_{-\infty}^x \int_{-\infty}^{\infty} f_{XY}(u, v) du dv$$

$$f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, v) dv$$

* FUNCIONS DISTRIBUCIO I DENSITAT CONDICIONADES

$$F_{Y|X}(y|X=x) = \frac{\partial / \partial x F_{XY}(x, y)}{f_X(x)}$$

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

$$f_Y(y) = \int_{-\infty}^{\infty} f_{Y|X}(y|x) \cdot f_X(x) dx$$

Versio continua
T² Prob. Total

$$f_{X|Y}(x|y) = \frac{f_{Y|X}(y|x) f_X(x)}{f_Y(y)}$$

Versio continua
de Bayes

* ESPERANCES CONDICIONADES

$$E(Y|B) = \int_{-\infty}^{\infty} y f_Y(y|B) dy$$

TEOREMA

$$E(E(Y|X)) = E(Y)$$

* SI X, Y v.a independents

$$F_{XY}(x, y) = F_X(x) F_Y(y) \quad ; \quad f_{XY}(x, y) = f_X(x) f_Y(y)$$

TEMA 6: FUNCIONS DE 2 V.A.

F. DISTRIBUCIÓ

$$F_Z(z) = \iint_{D_z} f_{XY}(x, y) dx dy$$

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

$$D_z = \{(x, y) : g(x, y) \leq z\}$$

F. DENSITAT

$$f_{ZT}(z, t) = \sum_{i=1}^n \frac{f_{XY}(x_i, y_i)}{|J(x_i, y_i)|}$$

$$\begin{cases} z = g(x, y) & \{ x_i = x_i(z, t) \\ t = h(x, y) & \{ y_i = y_i(z, t) \end{cases}$$

$$J(x, y) = \begin{vmatrix} \partial g / \partial x & \partial g / \partial y \\ \partial h / \partial x & \partial h / \partial y \end{vmatrix}$$

$f_{ZT}(z, t) = 0 \iff$ Si el sistema no té solució
 {no es poden expressar (x, y) en funció de (z, t) }

TEOR: Si X, Y v.a. indep $\Rightarrow f_Z(z) = f_X(x) * f_Y(y) \quad Z = X + Y$

* T₂ DE L'ESPERANÇA BIDIMENSIONAL

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

PROP:

1) Lineal $E(\alpha X + \beta Y) = \alpha E(X) + \beta E(Y)$

2) Si X, Y indep $E(X \cdot Y) = E(X)E(Y)$

- Moments de 2. va

- Moments centrats

$$m_{ij} = E(X^i Y^j)$$

$$\mu_{ij} = E((X - m_x)^i (Y - m_y)^j)$$

Covariància $\Rightarrow \mu_{11} = E(XY) - E(X)E(Y)$

* COEFICIENT DE CORRELACIÓ

$$\rho = \frac{\mu_{11}}{\sqrt{\mu_{20} \mu_{02}}} = \frac{\mu_{11}}{\sigma_x \sigma_y}$$

$$-1 \leq \rho \leq 1$$

$$\rho = 0 \iff X, Y \text{ v.a. indep}$$

$$|\rho| = 1 \iff X, Y \text{ depenen linealment}$$

$\rho = 0 \Rightarrow$ V.A. incorelades



$$F_Z(z) = F_{XY}(z, z)$$

- Funció mínim $\Rightarrow Z = \min(X, Y) \Rightarrow$



$$F_Z(z) = F_X(z) + F_Y(z) - F_{XY}(z, z)$$

TEMA 7: EXTENSIÓ AL CAS N-DIM

$$X = (X_1, X_2, \dots, X_n)$$

$$F_x(x_1, x_2, \dots, x_n) \equiv P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$$

$$f_x(x_1, x_2, \dots, x_n) = \frac{\partial^n F_x(x_1, x_2, \dots, x_n)}{\partial x_1 \partial x_2 \dots \partial x_n}$$

- Si f_x tendir a ∞ alguns dels arguments x_i obtenim la funció de distribució conjunta de les v_a corresponents als altres.

TEOR: Si X_1, X_2, \dots, X_n independents 2 a 2


$$\sigma_z^2 = \alpha_1^2 \sigma_{x_1}^2 + \alpha_2^2 \sigma_{x_2}^2 + \dots + \alpha_n^2 \sigma_{x_n}^2$$

$$f_y(y_1, y_2, \dots, y_n) = \sum_i \frac{f_x(x_1^i, \dots, x_n^i)}{|J(x_1^i, \dots, x_n^i)|} \quad y_k = g_k(x_1, x_2, \dots, x_n)$$

$$f_y(y_1, y_2, \dots, y_n) = 0 \text{ si no es pot expressar } (x_1, \dots, x_n) \text{ en funció } (y_1, \dots, y_n)$$

* LA LLEI DÈBIL DELS GRANS NOMBRES

X_1, X_2, \dots, X_n independents 2 a 2 amb $E(X_i) = m, \text{Var}(X_i) = \sigma^2 \forall i$



$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

$$E(\bar{X}) = m ; E(\bar{X}^2) = \frac{\sigma^2}{n} + m^2$$

$$\text{Var}(\bar{X}) = E(\bar{X}^2) - m^2$$

$$\boxed{n \rightarrow \infty} \quad f_y(y) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^y e^{-\frac{1}{2}t^2} dt \quad \text{Per a } n \text{ gran } Y \rightarrow \text{gauss}$$

* VARIABLES ALEATORIES GAUSSIANES N-DIM

$$K_x = \begin{pmatrix} k_{11} & \dots & k_{1n} \\ \vdots & & \vdots \\ k_{n1} & \dots & k_{nn} \end{pmatrix} \leftarrow \text{Matriu de covariàncies}$$

$$k_{ij} = k_{ji} \equiv \mu_{11}(X_i, X_j) = E((X_i - m_{x_i})(X_j - m_{x_j}))$$

$$\boxed{\text{Si } Y = A \cdot X \Rightarrow \begin{cases} m_y = A m_x \\ K_y = A K_x A^t \end{cases}}$$

$$m_x = \begin{pmatrix} m_{x_1} \\ m_{x_2} \\ \vdots \\ m_{x_n} \end{pmatrix}$$

* GAUSS CONDICIONADA

$$f_{y|x}(y|x) = \frac{1}{\sqrt{2\pi} \sigma'} e^{-\frac{1}{2} \left(\frac{y - m'}{\sigma'} \right)^2}$$

$$m' = \rho \frac{\sigma_y}{\sigma_x} (x - m_x) + m_y$$

$$\sigma' = \sqrt{1 - \rho^2} \sigma_y$$

TEMA 8 : ESTIMACIÓ DE V.A.

* Estimadors en mitjana quadràtica (m.q.)

\hat{Y} (Millor estimador de Y) $\Rightarrow \mathcal{E} \equiv E((Y - \hat{Y})^2)$ mínim

* ESTIMADOR EN M.Q. MITJANÇANT UNA CONSTANT $\hat{Y} = K$

$$\boxed{\hat{Y} = K = m_Y} \quad \boxed{E_{\min} = \sigma_Y^2}$$

* ESTIMADOR "NO LINEAL" EN M.Q.

$$\boxed{\hat{Y} = E(Y|X)}$$

PROP:

1) Si X, Y , v.a indep. $\Rightarrow \hat{Y} = E(Y)$

2) Lineals $\widehat{(Y_1 + Y_2)} = \hat{Y}_1 + \hat{Y}_2$; $\widehat{\alpha Y} = \alpha \hat{Y}$

3) $E(\hat{Y}) = E(Y)$

* ESTIMADOR LINEAL EN M.Q.

$$\hat{Y} = aX + b$$

$$\boxed{\hat{Y} = \rho \frac{\sigma_Y}{\sigma_X} (X - m_X) + m_Y}$$

$$\boxed{E_{\min} = (1 - \rho^2) \sigma_Y^2}$$

PROP:

1) $\rho = 0 \Rightarrow \hat{Y} = m_Y$; $E_{\min} = \sigma_Y^2$

2) X, Y conjuntament gaussianes \Rightarrow l'estimador lineal és optimit

3) Si $\hat{Y} = aX$ (estimador lineal homogeni) $\Rightarrow a = \frac{E(XY)}{E(X^2)}$

* PRINCIPI D'ORTOGONALITAT

$E(XY) = \langle X, Y \rangle$: defineix un prod. escalar

- Els valors de a, b que don mínim $\mathcal{E} = E((Y - \hat{Y})^2)$:

$$\begin{cases} \mathcal{E} \perp 1 \\ \mathcal{E} \perp X \end{cases} \left\{ \begin{array}{l} E(Y - \hat{Y}) = 0 \\ E((Y - \hat{Y})X) = 0 \end{array} \right.$$

$$E_{\min} = E((Y - \hat{Y})|Y)$$

$$a = \rho \frac{\sigma_X}{\sigma_Y} \quad b = m_Y - a m_X$$

- Estimador lineal multidimensional

$$\hat{Y} = a_1 X_1 + a_2 X_2 + \dots + a_n X_n + b$$

a_i i b q. minimitzen $E((Y - \hat{Y})^2) \Rightarrow b = m_Y - a_1 m_{X_1} - \dots - a_n m_{X_n}$

Principi ortog. $\left\{ \begin{array}{l} Y - \hat{Y} \perp 1 \\ Y - \hat{Y} \perp X_i \end{array} \right.$

TEMA 9: INTRODUCCIÓ ALS PROCESSOS ESTOCÀSTICS

- Procés estocàstic: Model matemàtic d'un senyal que varia aleatoriament amb el temps.

$$F_x(x; t) = P(X(t) \leq x)$$

$$F_x(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = P(X(t_1) \leq x_1, \dots, X(t_n) \leq x_n)$$

$$m_x(t) = \begin{cases} \int_{-\infty}^{\infty} x f_x(x; t) dx & X(t) \text{ continu en resultats} \\ \sum_k x_k P(X(t) = x_k) & X(t) \text{ discret en resultats} \end{cases}$$

* FUNCIÓ D'AUTOCORRELACIÓ

$$R_x(t_1, t_2) = E(X(t_1)X(t_2))$$

* * FUNCIÓ D'AUTOCONARIÀNCIA

$$C_x(t_1, t_2) = R_x(t_1, t_2) - m_x(t_1)m_x(t_2)$$

* PROCESOS ESTACIONARIS

- Un procés és estacionari en sentit estricte si les seves propietats probabilístiques no depenen de l'origen de temps fixat.


$$F_x(x; t) = F_x(x; t + \tau) \quad \text{no depenen de } t_1, t_2, \text{ només de } |t_2 - t_1|$$

$$m_x(t) = m_x \text{ (cte)}$$

$$R_x(t_1, t_2) = R_x(\tau)$$

$$C_x(t_1, t_2) = R_x(\tau) - m_x^2$$

PROPIETATS DE $R_x(\tau)$



- 1/ No depen de t
- 2/ És parella
- 3/ $R_x(t, t) = R_x(0) \equiv$ Potència mitjana $X(t)$
- 4/ $|R_x(\tau)| \leq R_x(0)$

- $X(t)$ és estacionari en sentit ampli si:

$$m_x(t) = m_x$$

$$R_x(t_1, t_2) = R_x(\tau)$$

P.E se
P.E sa



TEMA 10: EXEMPLES DE PROCESSOS ESTOCÀSTICS

- Procés de Poisson

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

- Senyal telegràfic

$$R_x(t_1, t_2) = \lambda \min(t_1, t_2) + \lambda^2 t_1 t_2$$

- Senyal telegràfic ...

TEMA 11: PROCESSOS ERGÒDICS

- Un procés estocàstic $X(t)$ és ergòdic si les seves propietats probabilístiques es poden obtenir processant en el temps una única realització del mateix.

* INTEGRALS DE PROCESSOS ESTOCÀSTICS

$$I = \int_a^b X(t) dt$$

$$m_I = \int_a^b m_x(t) dt$$

$$\sigma_I^2 = \int_a^b \int_a^b C_x(t_1, t_2) dt_1 dt_2$$

* ERGODICITAT EN VALOR MITJÀ

- Un procés (estacionari en s.a) és ergòdic en valor mitjà si podem obtenir m_x processant en el temps una única realització del procés.

$$\mathcal{M}_T \equiv \frac{1}{2T} \int_{-T}^T X(t) dt$$

Valor mitjà temporal de $X(t)$ en $[-T, T]$

$$E(\mathcal{M}_T) = m_x \quad \mathcal{M}_T \text{ és un estimador del paràmetre } m_x$$

Si $\sigma_T^2 = E((\mathcal{M}_T - m_x)^2) \xrightarrow{T \rightarrow \infty} 0 \Rightarrow X(t)$ es ergòdic en v.m en el sentit de m.o.g.

$$X(t) \text{ ergòdic en v.m} \Leftrightarrow \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T C_x(\tau) \left(1 - \frac{|\tau|}{T}\right) d\tau = 0$$

- Condició necessària: Si $\lim_{\tau \rightarrow \infty} C_x(\tau) \neq 0$

- Cond. suficients:

$$\int_{-\infty}^{\infty} |C_x(\tau)| d\tau < \infty$$

$$C_x(0) < \infty \text{ i } \lim_{\tau \rightarrow \infty} C_x(\tau) = 0$$

* ERGODICITAT EN AUTOCORRELACIÓ

- Podem obtenir $R_x(\tau) = E(X(t)X(t+\tau))$ processant en t una única...

$$E(R_T(\tau)) = E\left(\frac{1}{2T} \int_{-T}^T X(t)X(t+\tau) dt\right) = R_x(\tau)$$

Si $\text{Var}(R_T(\tau)) \xrightarrow{T \rightarrow \infty} 0$ $X(t)$ ergòdic en autocorrelació

$$\Phi_\tau(t) = X(t)X(t+\tau) \quad \text{Si } \Phi_\tau(t) \text{ ergò. en m.o.g.} \Rightarrow X(t) \text{ ergò. en autocorrelació}$$