


TRATAMIENTO ESTADÍSTICO DE SEÑALES

VARIABLES Y PROCESOS ALEATORIOS - CONCEPTOS

• Variable aleatoria X



valor medio: $\mu = E[x]$

pot. media: $P = E[x^2]$

varianza: $\sigma^2 = E[(x - E[x])^2]$

$$P = (\mu)^2 + (\sigma^2)$$

$$E[x] = \int x \cdot p(x) dx$$

$$E[f(x)] = \int f(x) \cdot p(x) dx$$

valor medio de x
def $f(x)$

$$E[x|y] = \int x \cdot p(x|y) dx$$

$$E[f(x_1, x_2)] = \int f(x_1, x_2) p(x_1, x_2) dx_1 dx_2$$

• fdp 2D



correlación $E[x \cdot y^*]$

covarianza $E[(x - E[x]) \cdot (y - E[y])^*]$

indep $\Leftrightarrow p(x, y) = p_1(x) \cdot p_2(y)$

$$E[x \cdot y] = E[x] \cdot E[y]$$

• V.A. Gaussiana

$$x: N(\mu, \sigma^2)$$

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

• V.A. Chi-cuadrado con N grados de libertad

Elevar el cuadrado un vector de N gaussianas

$$x = \sum_{i=1}^N z_i^2$$

$$p(x|H_i) = \frac{x^{(N-1)/2}}{2^{\frac{N}{2}} \sigma_i^2 \Gamma(\frac{N}{2})} \exp(-\frac{x}{2\sigma_i^2}) u(x)$$

$$\text{si } N=2 \rightarrow p(x|H_i) = \frac{1}{2\sigma^2} \exp(-\frac{x}{2\sigma^2}) u(x)$$

• V.A. Uniforme

$$E(X) = \frac{b+a}{2}$$

$$\text{var}(X) = \frac{(b-a)^2}{12}$$

• V.A. exponencial

$$f_X(x) = \alpha e^{-\alpha x} \quad E[X] = \frac{1}{\alpha}$$

$$\text{var}[X] = \frac{1}{\alpha^2}$$

• Proceso estocástico $X(n)$

estacionario \Rightarrow

media $\mu = E[x(n)]$

pot. media $P = E[x^2(n)]$

varianza $\sigma^2 = E[(x(n) - \mu)^2]$

autocorrelación

$$R(m) = E[x(n+m) \cdot x(n)^*]$$

$$P = R(m=0)$$

Dominio Frecuencial:

$$R(m) \xrightarrow{\text{TF}} S(\omega) \quad \begin{matrix} \text{densidad} \\ \text{espectral de} \\ \text{potencia} \end{matrix}$$

$$P = \frac{1}{2\pi} \int_0^{2\pi} S(\omega) d\omega$$

Filtrado de señales



$$\mu_y = \mu_x \cdot H(0)$$

$$S_y(\omega) = S_x(\omega) |H(\omega)|^2$$

$$R_y(m) = R_x(m) * h(m) * h^*(m)$$

$$R_{yx}(m) = R_x(m) * h(m)$$

Ruido blanco media nula

$$\begin{cases} \mu = 0 \\ R(m) = \begin{cases} P & m=0 \\ 0 & \text{resto} \end{cases} \end{cases} \quad S(\omega) = P$$

Función de V.A.

$$\begin{cases} y = f(x) \xrightarrow{\text{ }} p_x(x) \\ x = g(y) \end{cases}$$

$$p_y(y) = p_x(x) \cdot \frac{dx}{dy}$$

Fácil recordar

$$dx p(x) = dy p(y)$$

Función suma de 2 V.A.

$$X = Y + Z$$

$$p_x(x) = p_y(y) * p_z(z)$$

convolución

Cálculos típicos

VECTOR de observaciones: $\mathbf{y} = [y_0, y_1, \dots, y_{N-1}]^T$

$$\rightarrow P_r(\mathbf{y}) = \prod_{i=0}^{N-1} P_r(y_i)$$

$$\rightarrow p(\mathbf{y} | \alpha) = \prod_{i=0}^{N-1} p(y_i | \alpha)$$

ej. típico $y_i = \alpha + n_i \sim N(0, \sigma_n^2)$

$$p(y | \alpha) = \prod_{i=0}^{N-1} \frac{1}{\sqrt{2\pi\sigma_n^2}} e^{-\frac{(y_i - \alpha)^2}{2\sigma_n^2}} = \frac{1}{(2\pi\sigma_n^2)^{\frac{N}{2}}} \prod_{i=0}^{N-1} \left(e^{-\frac{(y_i - \alpha)^2}{2\sigma_n^2}} \right)$$

$$\ln p(\mathbf{y} | \alpha) = K - \sum_{i=0}^{N-1} \frac{(y_i - \alpha)^2}{2\sigma_n^2}$$

VARIANZA (calcular autocorrelación)

$$\text{ej. } \mathbf{y} \rightarrow y_i = \alpha + n_i \sim N(0, \sigma_n^2)$$

$$\rightarrow \hat{\alpha}_{ML} = \frac{1}{N} \sum_{i=0}^{N-1} y_i$$

$$\text{var}(\hat{\alpha}_{ML})$$

$$= E[\hat{\alpha}_{ML}^2] - E^2[\hat{\alpha}_{ML}]$$

$$= E\left[\frac{1}{N^2} \sum_i \sum_j y_i y_j\right] - \alpha^2$$

$$= \frac{1}{N^2} \sum_i \sum_j E[y_i y_j] - \alpha^2$$

$$\begin{cases} E[y_i^2] = \sigma_n^2 + \alpha^2 & \text{si } i=j \\ E[y_i y_j] = E[y_i] \cdot E[y_j] = \alpha^2 & \text{si } i=j \end{cases}$$

$$\begin{cases} \text{indep} & \text{if } i \neq j \end{cases}$$

$$= \frac{1}{N^2} \left[\sum_i (\sigma_n^2 + \alpha^2) + \sum_{i \neq j} \alpha^2 \right] - \alpha^2$$

$$= \frac{1}{N^2} \left[N \cdot (\sigma_n^2 + \alpha^2) + N(N-1)\alpha^2 \right] - \alpha^2 = \frac{\sigma_n^2}{N}$$

$$\text{cov}(\hat{\alpha}_{ML}, \hat{\alpha}_{ML}) = \text{var}(\hat{\alpha}_{ML})$$

A.V. = A.V.

$$\text{E}[N(\mu, \sigma^2)] = \mu$$

A.V. = A.V. con N fuentes de ruido

$$\sum_{i=1}^n \mathbb{E}[x_i] = \mu$$

$$\text{var}\left(\frac{1}{n} \sum_{i=1}^n x_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{var}(x_i) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{\sigma^2}{n}$$


A.V. = A.V.

$$\frac{\partial \mathbb{E}[X]}{\partial t} = \mathbb{E}[\partial X / \partial t]$$

A.V. = A.V.

ESTIMACIÓN

Espacios involucrados



Estimadores óptimos

- Maximum a Posteriori [MAP] $\hat{\alpha}_{MAP} = \max_{\{\alpha\}} (p(\alpha|y))$ ← útil para entenderlo
 $= \max (p(y|\alpha) \cdot p(\alpha))$ ← útil para calcular

- Máxima Verosimilitud [ML] $\hat{\alpha}_{ML} = \max (p(y|\alpha))$ no tiene en cuenta la prob del parámetro (α determinista)
 ↓
 no conocemos su jdp

- Bayes [BAYES] Función error/coste $\mathcal{E}(\alpha, \hat{\alpha}) = \begin{cases} |\alpha - \hat{\alpha}| \\ (\alpha - \hat{\alpha})^2 \end{cases}$

$\hat{\alpha}_{Bayes} = \min_{\hat{\alpha}} E[\mathcal{E}(\alpha, \hat{\alpha})]$ → minimiza el coste
 $= \min_{\hat{\alpha}} \iint \mathcal{E}(\alpha, \hat{\alpha}) \cdot p(\alpha, y) d\alpha dy$ ↓ irrelevant para y conocido

$\hat{\alpha}_{Bayes} = \min_{\hat{\alpha}} \int \mathcal{E}(\alpha, \hat{\alpha}) \cdot p(\alpha|y) d\alpha$ coste medio condicionado a y

para $\mathcal{E} = (\alpha - \hat{\alpha})^2$: $\hat{\alpha}_{ECM} = E[\alpha|y]$

Demostración:
 si $\mathcal{E}(\alpha, \hat{\alpha}) = (\alpha - \hat{\alpha})^2$
 entonces $\min \int (\alpha - \hat{\alpha})^2 p(\alpha|y) d\alpha$
 $\frac{d}{d\hat{\alpha}} \left(\int (\alpha - \hat{\alpha})^2 p(\alpha|y) d\alpha \right) = 0$
 $= -2 \int (\alpha - \hat{\alpha}) p(\alpha|y) d\alpha$
 $\hat{\alpha} = \underbrace{\int \alpha p(\alpha|y) d\alpha}_{E[\alpha|y]} = \frac{\int \hat{\alpha} p(\alpha|y) d\alpha}{\hat{\alpha} \cdot \underbrace{\int p(\alpha|y) d\alpha}_{1}}$

MAP coge el máximo de $p(\alpha|y)$
 BAYES coge la media

BAYES lógico:
 - si yo no midiese nada, tomaría $\hat{\alpha} = E[\alpha]$, pero si he medido y , lo condicioneo $\hat{\alpha} = E[\alpha|y]$

Propiedades de los estimadores

- Sesgo($\hat{\alpha}$) = $E[\hat{\alpha}] - E[\alpha]$
- Varianza($\hat{\alpha}$) = $E[(\hat{\alpha} - E[\hat{\alpha}])^2]$
 $= E[\hat{\alpha}^2] - E[\hat{\alpha}]^2$

$$E[\epsilon] = \text{sesgo}^2(\hat{\alpha}) + \text{var}(\hat{\alpha})$$

- Cota de Cramer-Rao
 Suponiendo α determinista & insesgado
 Nunca podemos conseguir que $\text{var}(\hat{\alpha}) < \text{CRB}$

$$\text{CRB} = \frac{-1}{E \left[\frac{\partial^2}{\partial \alpha^2} \ln(p(y|\alpha)) \right]}$$

- insesgado: $E[\hat{\alpha}] = E[\alpha]$

- consistente: $\lim_{N \rightarrow \infty} \text{var}(\hat{\alpha}) = 0$


- mínima varianza: $\text{var} \hat{\alpha}_{MV} < \text{var} \hat{\alpha}$ para cualquier $\hat{\alpha}$

- eficiente: $\text{var} \hat{\alpha} = \text{CRB}$

puedo acercarme todo lo que quiera usando suficientes muestras

DETECCIÓN

Test de Hipótesis



	Coste
• Func normal $H_0 \rightarrow D_0$	C_{00}
• Detección $H_1 \rightarrow D_1$	C_{11}
• Falsa Alarma $H_0 \rightarrow D_1$	C_{10}
• Miss $H_1 \rightarrow D_0$	C_{01}

Criterios de decisión

• MAP

$$p(H_1|z) \stackrel{H_1}{\geq} p(H_0|z) \quad \leftarrow \text{entenderlo Bayes}$$

$$p(z|H_1) \cdot p(H_1) \stackrel{H_1}{\geq} p(z|H_0) \cdot p(H_0) \quad \leftarrow \text{aplicarlo}$$

$$\frac{p(z|H_1)}{p(z|H_0)} \stackrel{H_1}{\geq} \frac{H_1}{H_0} \quad \frac{p(H_0)}{p(H_1)} \stackrel{\lambda}{\geq}$$

$\Lambda(z)$ razón de verosimilitud

umbral (no umbral en $\Lambda(z)$)

Falsa Alarma: $P_{FA} = \int_{Z_1} p(z|H_0) dz$

Miss: $P_M = \int_{Z_0} p(z|H_1) dz$

Prob. error: $P_e = P_{FA} \cdot P(H_0) + P_M \cdot P(H_1)$

Estas regiones son las ML. En MAP habría que corregir

• ML

$$p(z|H_1) \stackrel{H_1}{\geq} p(z|H_0)$$

$$\frac{p(z|H_1)}{p(z|H_0)} \stackrel{H_1}{\geq} 1$$

• Bayes

Elegir la región Z_0 que minimiza la parte variable del coste medio

$$p(H_1)(C_{01}-C_{11})p(z|H_1) \stackrel{H_1}{\geq} p(H_0)(C_{10}-C_{00})p(z|H_0)$$

MISS DETECT \uparrow

\uparrow $p(z|H_1)$

$$\frac{p(z|H_1)}{p(z|H_0)} \stackrel{H_1}{\geq} \frac{C_{10}-C_{00}}{C_{01}-C_{11}} \frac{p(H_0)}{p(H_1)}$$

$\Lambda(z)$

λ

• Mínima prob. de error

supone $C_{00} = C_{11} = 0$ $\Rightarrow \bar{C} = P_e \Rightarrow$

$C_{01} = C_{10} = 1$

minimizar coste (Bayes)
III
minimizar P_e (MAP)

• Minimax

No conocemos $P(H_1)$ así que tomamos el caso peor suponemos $P(H_1) = P_1$

COSTE MEDIO

$$\bar{C} = C_{00} \cdot P(H_0, D_0) + C_{11} \cdot P(H_1, D_1) + C_{10} \cdot P(H_0, D_1) + C_{01} \cdot P(H_1, D_0)$$

$$= C_{00} \cdot P(H_0) \int_{Z_0} p(z|H_0) dz + C_{11} \cdot P(H_1) \cdot [1 - \int_{Z_0} p(z|H_1) dz] + C_{10} \cdot P(H_0) \cdot [1 - \int_{Z_0} p(z|H_0) dz] + C_{01} \cdot P(H_1) \cdot \int_{Z_0} p(z|H_0) dz$$

Lógicamente $\int_{Z_1} p(z|H_1) dz = 1 - \int_{Z_1} p(z|H_1) dz$
lo hacemos para integrar siempre en Z_0

$$\bar{C} = C_{11} p(H_1) + C_{10} p(H_0) + \int_{Z_0} p(H_1) (C_{01} - C_{11}) p(z|H_1) - p(H_0) (C_{10} - C_{00}) p(z|H_0) dz$$

$$= C_{11} p(H_1) + C_{10} p(H_0) + (C_{01} - C_{11}) p(H_1) \int_{Z_0} p(z|H_1) dz - (C_{10} - C_{00}) p(H_0) \int_{Z_0} p(z|H_0) dz$$


λ

P_M

y utilizando que $P(H_0) = 1 - P(H_1)$ se llega a

$$\bar{C} = C_{00}(1 - P_F) + C_{10} P_F + p(H_1) [(C_{11} - C_{00}) + (C_{01} - C_{11}) P_M - (C_{10} - C_{00}) P_F]$$

La relación con $P(H_1)$ es:



$$P_1 \Leftrightarrow \frac{d\bar{C}}{dP(H_1)} = 0 \Leftrightarrow \frac{(C_{11} - C_{00}) + (C_{01} - C_{11}) P_M - (C_{10} - C_{00}) P_F}{P_1} = 0$$

λ

$P_M = P_{FA}$

III

- Criterio de Neymann-Pearson

- C_{ij} desconocidas
 $p(H_i)$ desconocidas

se trata de fijar $P_{FA} = \alpha$ (dato) y minimizar P_M (max PDET)

Para ello

$$\frac{p(z|H_1)}{p(z|H_0)} \geq \lambda \rightarrow \text{Umbral de Neymann Pearson}$$

Hay que determinar el umbral exigiendo:

$$P_{FA} = \int_{z_1}^{\infty} p(z|H_0) dz = \alpha$$

• Hipótesis múltiple

M>2 eventos $H_0, H_1, H_2, \dots, H_{M-1} \rightarrow M$ zonas de decisión

El coste medio:

$$\bar{C} = \sum_{i=0}^{M-1} \sum_{j=0}^{M-1} C_{ij} \cdot P(H_j) \cdot P(D_i | H_j)$$

$$= \dots = \underbrace{\sum_{i=0}^{M-1} C_i P(H_i)}_{\text{coste fijo}} + \underbrace{\sum_{i=0}^{M-1} \int \sum_{\substack{j=0 \\ j \neq i}}^{M-1} P(H_j) (C_{ij} - C_{jj}) P(z | H_j) dz}_{\text{coste variable que minimizamos}}$$

Escogemos las Z_i que MINIMICEN

$$\begin{aligned}
 I_c(z) &= \sum_{j \neq 0} P(H_j) (C_{ij} - C_{jj}) P(z|H_j) \quad \Rightarrow \quad J_c(z) = \sum_{j \neq 0} P(H_j) (C_{ij} - C_{jj}) \cdot \frac{P(z|H_j)}{P(z|H_0)} \\
 I_1(z) &= \sum_{j \neq 1} P(H_j) (C_{ij} - C_{jj}) P(z|H_j) \quad \Rightarrow \quad J_1(z) = \sum_{j \neq 1} P(H_j) (C_{ij} - C_{jj}) \cdot \frac{P(z|H_j)}{P(z|H_0)} \\
 &\vdots &&\vdots \\
 I_i(z) &= \sum_{j \neq i} P(H_j) (C_{ij} - C_{jj}) P(z|H_j) \quad \Rightarrow \quad J_i(z) = \sum_{j \neq i} P(H_j) (C_{ij} - C_{jj}) \frac{P(z|H_j)}{P(z|H_0)} \\
 &&&\text{normalizando} \\
 &&&\text{por } P(z|H_0) && J_i(z)
 \end{aligned}$$

$$z \in Z_i \iff J_i(z) \leq J_j(z) \quad \forall j$$

↳ Condición en el dominio $J(z) \rightarrow \lambda(z)$
Hay que convertirla en condición en el dominio z

CLASIFICACIÓN


Problema de clasificación



- Preprocessing
 - sensing
 - separate features from one another and from background (segmentation)

Feature extraction
Reduce data by measuring certain features
e.g.
lightness
length
width

- Classifier
Threshold decision



salmon
sea bass

Generalization

- control trade-off between training error and test error

e.g.



would give 0% training-error but bad test-error

OVERFITTING

Tipos

Statistical learning

$$x \rightarrow f(\cdot) \rightarrow y$$

- Supervised learning : - sample set of x and y during training
- $f(\cdot)$ is learned

- Unsupervised learning (clustering)
 - only x is known
 - try to cluster data into sets

- $Y = \{0, 1\} \rightarrow$ detection
- $Y = \{0, 1, 2, \dots, N\} \rightarrow$ classification
- $Y = \mathbb{R} \rightarrow$ regression

Bayesian Theory

$$P_{x,y}(x,i) = P_{x|y}(x|i) \cdot P_y(i)$$


marginalization (eliminating variables) $P_{x_1, x_4}(x_1, x_4) = \int \int P_{x_1, x_2, x_3, x_4}(x_1, x_2, x_3, x_4) dx_2 dx_3$

Bayes Rule : $P_{y|x}(y|x) = \frac{P_{x|y}(x|y) \cdot P_y(y)}{P_x(x)}$ \rightarrow no importante para clasificar

MAR Rule
classification

$$i^*(x) = \arg \max_i \underbrace{P(x|y)}_{ML} \cdot \underbrace{P(y)}_{\text{Prior}}$$

Gaussiana en 1D



$\frac{1}{(\mu_1 - \mu_0)^2}$ weighs the prior
 $\sqrt{\sigma^2}$ distance between the means in units of variance

- classes very far apart : "forget the prior"
- classes with same mean "forget the observation, use prior!"

$$y \geq \frac{\mu_1 + \mu_0}{2} + \frac{1}{(\mu_1 - \mu_0)^2} \cdot \ln \frac{P(0)}{P(1)}$$

The Gaussian Classifier

Gaussian
N-dim.

$$P_{X|Y}(\vec{x}|i) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_i|}} e^{-\frac{1}{2} (\vec{x} - \vec{\mu}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{\mu}_i)}$$

$$\text{MAP } i^*(\vec{x}) = \arg \max [\ln P_{X|Y}(\vec{x}|i) + \ln P_Y(i)]$$

General Case

$$\vec{\mu}_1, \vec{\mu}_2$$

$$\Sigma_1, \Sigma_2$$


$$i^*(\vec{x}) = \arg \min \left[(\vec{x} - \vec{\mu}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{\mu}_i) + \ln(2\pi)^d |\Sigma_i| - 2 \ln P_Y(i) \right]$$

Mahalanobis distance $d_i(\vec{x}, \vec{\mu}_i)$

class prior

→ Special case: all classes have same covariance

$$\Sigma_i = \Sigma$$



$$\text{Hyperplane } \vec{w}^T \cdot (\vec{x} - \vec{x}_0) = 0$$

passes through \vec{x}_0
normal to \vec{w}

changes direction
direction joining
the means

$$\vec{w} = \Sigma^{-1} \cdot (\vec{\mu}_i - \vec{\mu}_j)$$

$$\vec{x}_0 = \frac{\vec{\mu}_i + \vec{\mu}_j}{2} - \frac{(\vec{\mu}_i - \vec{\mu}_j)}{(\vec{\mu}_i - \vec{\mu}_j)^T \Sigma^{-1} (\vec{\mu}_i - \vec{\mu}_j)} \ln \frac{P_Y(i)}{P_Y(j)}$$

midpoint

weight to prior

Mahalanobis
distance between
means

$$\Sigma = \sigma^2 \mathbb{I}$$

Mahalanobis distance becomes EUCLIDEAN DISTANCE SQUARED in units of variance

$$d_i(\vec{x}_1, \vec{x}_2) = \frac{\|\vec{x}_1 - \vec{x}_2\|^2}{\sigma^2}$$

El peso al prior pasa a ser:


$$\frac{\vec{\mu}_i - \vec{\mu}_j}{\|\vec{\mu}_i - \vec{\mu}_j\|^2}$$

clara analogía al 1D

→ sub-special case:

same variance along all dimensions
(variables incorreladas)

$$\Sigma = \sigma^2 \mathbb{I} = \begin{bmatrix} \sigma^2 & & \\ & \ddots & \\ & & \sigma^2 \end{bmatrix}$$



$$\vec{w} = \frac{\vec{\mu}_i - \vec{\mu}_j}{\sigma^2}$$

along the line joining the means

$$\vec{x}_0 = \frac{\vec{\mu}_i + \vec{\mu}_j}{2} - \frac{(\vec{\mu}_i - \vec{\mu}_j)}{\left(\frac{\|\vec{\mu}_i - \vec{\mu}_j\|^2}{\sigma^2} \right)} \cdot \ln \frac{P_Y(i)}{P_Y(j)}$$

→ sub-special case
 $P_Y(i) = P_Y(j)$
equiprobables

$$\vec{x}_0 = \frac{\vec{\mu}_i + \vec{\mu}_j}{2}$$


midpoint of the means



$$\frac{0.9}{0.1} \cdot \frac{1}{(x - \mu_i)^2} + \frac{0.1}{0.9} \cdot \frac{1}{(x - \mu_j)^2} \leq 1$$

ESTIMACIÓN

Espacios involucrados y modelos de probabilidad



Estimadores óptimos

1. Estimador "Maximum a posteriori" (MAP)

Supondremos α aleatorio con $p(\alpha)$ conocida (si no conociesemos $p(\alpha)$ podríamos decir que es determinista desconocido)


$$\hat{\alpha}_{\text{MAP}} = \hat{\alpha}(y) = \max_{\{\alpha\}} P(y, \alpha)$$

↑
he medido
en y

me muevo
en α para
buscar el max.

Es engoroso trabajar con $P(y, \alpha)$
Pero aplicando Teorema de Bayes

$$P(y, \alpha) = \frac{P(y|\alpha) \cdot P(\alpha)}{P(y)} \quad \text{no depende de } \alpha$$



$$\begin{aligned} \hat{\alpha}_{\text{MAP}} &= \max_{\{\alpha\}} \underbrace{P(y|\alpha) \cdot P(\alpha)}_{= P(\alpha|y)} \\ &= P(\alpha|y) \end{aligned}$$

en la práctica ésta es la función fácil de conseguir
es equivalente a maximizar $P(\alpha|y)$ lo cual le da nombre al método

A la función que maximizamos ($P(y, \alpha) \rightarrow P(y|\alpha) \cdot P(\alpha) \rightarrow P(\alpha|y)$) se le llama función de verosimilitud (likelihood)

$$l(y|\alpha)$$

$$\ln[l(y|\alpha)] = L(y|\alpha) \quad \text{función logarítmica de verosimilitud}$$

ejemplo 1:

$$\text{suponemos } \mathbf{y} = [y_0, y_1, \dots, y_{N-1}]^T$$

$$\text{donde } y_i = a + n_i$$

$$\xrightarrow{\text{v.a.}} n_i \sim N(0, \sigma_n^2)$$

$$\xrightarrow{\text{v.a.}} a \sim N(0, \sigma_a^2)$$

distrib
normal

'a' es una V.A. pero
es fija para todas
las observaciones

a y n_i son independientes
n_i independientes entre si

Encontrar \hat{a}_{MAP}

$$\text{Buscamos } p(a | \mathbf{y}) = p(\mathbf{y} | a) \cdot p(a)$$

$$\left\{ \begin{array}{l} p(\mathbf{y} | a) = \prod_{i=0}^{N-1} \frac{1}{\sqrt{2\pi\sigma_n^2}} e^{-\frac{(y_i-a)^2}{2\sigma_n^2}} = \frac{1}{(2\pi\sigma_n^2)^{N/2}} \prod_{i=0}^{N-1} e^{-\frac{(y_i-a)^2}{2\sigma_n^2}} \\ \uparrow y = a + n \end{array} \right.$$

la prob del vector será
la prob de que se cumplan
todas sus elementos
(que como son independientes)
es el producto de
gaussianas

$$p(a) = \frac{1}{\sqrt{2\pi\sigma_a^2}} e^{-\frac{a^2}{2\sigma_a^2}}$$

La función logarítmica de verosimilitud será

$$\ln(a | \mathbf{y}) = K - \frac{a^2}{2\sigma_a^2} - \sum_{i=0}^{N-1} \frac{(y_i-a)^2}{2\sigma_n^2}$$

Hay que maximizar esta función con respecto a 'a'

$$\begin{aligned} \frac{\partial \ln(a | \mathbf{y})}{\partial a} &= -\frac{a}{\sigma_a^2} + \sum_{i=0}^{N-1} \frac{(y_i-a)}{\sigma_n^2} \\ &= -a \left(\frac{1}{\sigma_a^2} + \frac{N}{\sigma_n^2} \right) + \sum_{i=0}^{N-1} \frac{y_i}{\sigma_n^2} = 0 \end{aligned}$$

despejamos \hat{a}_{MAP}
que cumple esta
ecuación

$$\Rightarrow \hat{a}_{MAP} = \frac{1}{\frac{\sigma_n^2}{\sigma_a^2} + N} \cdot \sum_{i=0}^{N-1} y_i$$

Esta fórmula es muy lógica
sobre todo si la vemos en casos
extremos

si $\frac{\sigma_n^2}{\sigma_a^2} \ll N \rightarrow \hat{a}_{MAP} \approx \frac{1}{N} \sum_{i=0}^{N-1} y_i$ la media de las
 $\sigma_a \uparrow \uparrow$ observaciones

si $\frac{\sigma_n^2}{\sigma_a^2} \gg N \rightarrow \hat{a}_{MAP} \approx \frac{\sigma_a^2}{\sigma_n^2} \sum_{i=0}^{N-1} y_i$ iesta ya no es tan
 $\uparrow \uparrow$ intuitivo!

sabiendo que $\sigma_a \rightarrow 0$ el valor estimado le reducimos acercándolo a 0

2. Estimador de máxima verosimilitud (ML)


Suponemos α determinista

$$\hat{\alpha}_{ML} = \max_{\{\alpha\}} p(y|\alpha)$$

Equivale a MAP
en el caso de
 $p(\alpha) = K$ uniforme

Es decir, no introducimos información
a priori acerca del parámetro

ejemplo: si α tiene dos posibilidades α_1, α_2



ejemplo 2: igual que 1 pero 'a' determinista

$$\ln\{p(y|a)\} = K - \sum_{i=0}^{N-1} \frac{(y_i - a)^2}{2\sigma^2} \quad \text{función logarítmica de verosimilitud}$$

maximizando respecto a 'a'

$$\frac{\partial \ln p(y|a)}{\partial a} = - \sum_{i=0}^{N-1} \frac{(y_i - a)}{\sigma^2} = 0 \rightarrow$$

$$\hat{a}_{ML} = \frac{1}{N} \sum_{i=0}^{N-1} y_i$$

coincide con el MAP cuando no
hay info de 'a' a priori
 $\sigma_a^2 \rightarrow \infty$

En resumen:

$$\hat{\alpha}_{ML} = \max_{\alpha} p(y|\alpha) \quad \begin{matrix} \text{escoge el parámetro que da la} \\ \text{máxima probabilidad de lo que he medido} \end{matrix}$$

$$\hat{\alpha}_{MAP} = \max_{\alpha} p(\alpha|y) = \max_{\alpha} p(y|\alpha) \cdot p(\alpha) \quad \begin{matrix} \text{escoge el parámetro que con} \\ \text{máxima probabilidad ha} \\ \text{generado lo que he medido} \end{matrix}$$

←
 ↘
 no estoy seguro

3. Estimador de Bayes

Cada pareja $\alpha, \hat{\alpha}$ tiene un coste (típicamente grande si he errado mucho) a través de una función de coste típicamente

$$C(\alpha, \hat{\alpha})$$

$$C(\alpha, \hat{\alpha}) = \begin{cases} (\alpha - \hat{\alpha})^2 \\ |\alpha - \hat{\alpha}| \end{cases} = \varepsilon(\alpha, \hat{\alpha})$$

↓
será una
V.A.
: valor medio
: varianza

El estimador de Bayes trata de minimizar el valor medio del coste (i.e. minimiza el 'error' medio)

$$\hat{\alpha}_{\text{BAYES}} = g(y) \text{ tal que } E[\varepsilon(\alpha, \hat{\alpha})] = \iint \varepsilon(\alpha, g(y)) \cdot p(\alpha, y) d\alpha dy \text{ sea mínimo}$$

Recuerda

$$E\{X\} = \int x \cdot p(x) dx$$

$$E\{j(x)\} = \int j(x) \cdot p(x) dx$$

$$E\{f(x_1, x_2)\} = \int f(x_1, x_2) \cdot p(x_1, x_2) dx_1 dx_2$$

se puede expresar la integral:

$$E[\varepsilon(\alpha, \hat{\alpha})] = \iint \varepsilon(\alpha, g(y)) \underbrace{p(\alpha, y)}_{p(\alpha|y) \cdot p(y)} d\alpha dy$$

$$= \int p(y) \underbrace{\left[\int \varepsilon(\alpha, g(y)) p(\alpha|y) d\alpha \right]}_{\substack{\text{siempre} \\ \text{es positivo}}} dy$$

esto dará lugar a un valor que depende de y

↓
puedo limitarme a minimizar esto

(llamado: Coste medio condicionado a y)

si lo minimizo para todo y estaré minimizando todo el coste medio

• caso particular:

$$\text{si escogemos } E(\alpha, g(y)) = (\alpha - g(y))^2 = (\alpha - \hat{\alpha})^2$$

i.e. error cuadrático como función de coste

• Sustituyendo en la integral anterior

• Derivando respecto a α (g aunque dependa de y)

• Igualando a cero

$$\frac{\delta}{\delta g} \int (\alpha - g(y))^2 p(\alpha | y) d\alpha = -2 \int (\alpha - g(y)) \cdot p(\alpha | y) d\alpha = 0$$

$$\Rightarrow \underbrace{\int \alpha p(\alpha | y) d\alpha}_{E\{\alpha | y\}} = \int g(y) \cdot p(\alpha | y) d\alpha = g(y) \cdot \underbrace{\int p(\alpha | y) d\alpha}_{=1}$$

La integral de CUALQUIER densidad de probabilidad (aunque sea condicionada, etc...) debe ser 1

$$\Rightarrow \hat{\alpha}_{\text{BAYES}} = E\{\alpha | y\}$$

- En general es un proceso no lineal en y
- si todo es gaussiano, sí es un operador lineal (es decir $\alpha = A \cdot y$)


Es lógico:

si yo no midiere nada, tomaría $\hat{\alpha} = E[\alpha]$

pero si he medido y , tomo el valor medio CONDICIONADO a y

Es decir:

MAP coge el MÁXIMO de $p(\alpha | y)$
BAYES coge la MEDIA de $\alpha | y$



ejemplo 3

minimiz. error cuadrático medio

$$y = [y_0, \dots, y_{N-1}]^T$$

$$y_i = a + n_i$$

$$a: N(0, \sigma_a^2)$$

$$n_i: N(0, \sigma_n^2)$$

$$\hat{\alpha}_{\text{BAYES}} \downarrow = E[a | y] = \int_{-\infty}^{\infty} a \cdot p(a | y) da$$

recuerda:

$$p(a | y) = \frac{1}{(2\pi\sigma_n^2)^{N/2}} \left[\prod_{i=0}^{N-1} e^{-\frac{(y_i - a)^2}{2\sigma_n^2}} \right] \frac{1}{\sqrt{2\pi\sigma_a^2}} e^{-\frac{a^2}{2\sigma_a^2}}$$

Propiedades de los estimadores

- Insegado: $E[\hat{\alpha}] = E[\alpha]$ i.e. si hago ∞ estimaciones, la media será el valor correcto
 $\text{sesgo}(\hat{\alpha}) = E[\hat{\alpha}] - E[\alpha]$
- Consistente: $\lim_{N \rightarrow \infty} \Pr(\hat{\alpha} - \alpha < \varepsilon) = 0$ i.e. puedo conseguir que el valor estimado sea tan cercano al real como se desee sin más que repetir la estimación N veces
- Minima varianza: $\text{var} \hat{\alpha}_{\text{MV}} \leq \text{var} \hat{\alpha}$, para cualquier $\hat{\alpha}$
 recuerda, se cumple:

$$E[\varepsilon^2] = \text{var} \hat{\alpha} + \text{sesgo}^2(\hat{\alpha})$$

$\varepsilon = y - \alpha$ Normalmente preocupa más la varianza que el sesgo.
 (a veces el sesgo se puede compensar)
- Cota de Cramer-Rao
 suponiendo α determinista, $\hat{\alpha}$ insegado
 $\text{var}(\hat{\alpha}) \geq \text{CRB}$ nunca podemos conseguir que la varianza baje por debajo de la cota.
 La distancia a la cota indica lo mejorable que es el estimador

$$\text{CRB} = \frac{E_y \left[\frac{\partial^2}{\partial \alpha^2} \ln(p(y|\alpha)) \right]}{n (f'(\alpha))^2}$$
- Estimador eficiente $\text{var}(\hat{\alpha}) = \text{CRB}$

ejemplo 4: ML

Hipótesis de ejemplos 1, 2, 3

$$\hat{a}_{ML} = \frac{1}{N} \sum_{i=0}^{N-1} y_i$$

$$E[\hat{a}_{ML}] = \frac{1}{N} \sum_{i=0}^{N-1} E[y_i] = a \rightarrow \text{estimador insesgado}$$

$$\text{var}[\hat{a}_{ML}] = E[\hat{a}_{ML}^2] - E^2[\hat{a}_{ML}]$$

$$= E\left[\frac{1}{N^2} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} y_i y_j\right] - a^2$$

$$= \frac{1}{N^2} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} E[y_i y_j] - a^2$$

$$\boxed{= \begin{cases} E[y_i^2] = \sigma_n^2 + a^2 & \text{si } i=j \\ E[y_i y_j] = E[y_i] \cdot E[y_j] = a^2 & \text{si } i \neq j \end{cases} \text{ independientes}}$$

(i)

$$= \frac{1}{N^2} \left[\sum_{i=0}^{N-1} E[y_i^2] + \sum_{i=0}^{N-1} \sum_{j \neq i}^{N-1} E[y_i] \cdot E[y_j] \right] - a^2$$

$$= \frac{1}{N^2} \left[N \cdot (\sigma_n^2 + a^2) + (N(N-1)) \cdot a^2 \right] - a^2$$


$$\boxed{\text{var } \hat{a}_{ML} = \frac{\sigma_n^2}{N}}$$

Estamos reduciendo el ruido

$$\begin{cases} y_i = a + n_i & \xrightarrow{\sigma_n^2} \\ \hat{a}_{ML} = a + n'_i & \xrightarrow{\frac{\sigma_n^2}{N}} \end{cases}$$

$$\text{var } \hat{a}_{ML} \xrightarrow[N \rightarrow \infty]{} 0 \rightarrow \text{estimador consistente}$$

si te fijas bien, \hat{a}_{ML} en este caso no es mas que un filtro FIR que elimina ruido



Calculemos la Cota de Kramer-Rao

recuerda que ya tenemos

$$\frac{\partial \ln p(y|a)}{\partial a} = \frac{\partial}{\partial a} \left\{ K - \sum_{i=0}^{N-1} \frac{(y_i - a)^2}{2\sigma_n^2} \right\}$$

$$= \frac{1}{2\sigma_n^2} (-2) \sum_{i=0}^{N-1} (y_i - a)(-1) = \frac{1}{\sigma_n^2} \sum_{i=0}^{N-1} (y_i - a)$$

$$\frac{\partial^2 \ln(p(y|a))}{\partial^2 a} = \frac{1}{\sigma_n^2} \sum_{i=0}^{N-1} (-1) = \frac{-N}{\sigma_n^2}$$

$$\text{CRB} = -\frac{1}{E\left[\frac{\partial^2 \ln p(y|a)}{\partial^2 a}\right]} = \frac{\sigma_n^2}{N}$$

$$\text{var } \hat{a}_{ML} = \text{CRB} \rightarrow \text{estimador eficiente}$$

Si el ruido no fuese gaussiano, habrían otras formas mejores de estimar el valor medio

Ejemplo 5.

Demostrar que cualquier estimador de Bayes es insesgado
(lo demostramos para el caso del error cuadrático como función de coste)

$$\begin{aligned}
 E[\hat{\alpha}_{\text{BAYES}}] &= E[E[\alpha | y]] \\
 &\quad \uparrow \quad \uparrow \\
 &\quad \text{valor} \quad \text{valor medio} \\
 &\quad \text{medio} \quad \text{de } x \text{ en} \\
 &\quad \text{de la} \quad \text{la función} \\
 &\quad \text{estima} \quad p(\alpha | y) \\
 &\quad \text{para varias} \quad (\text{i.e. aleatoriedad en } \alpha) \\
 &\quad \text{observaciones} \\
 &\quad (\text{i.e. la aleatoriedad} \\
 &\quad \text{es en } y) \\
 &\quad \text{v.a.} \\
 &= E\left[\int \alpha \cdot p(\alpha | y) dx \right] = \int \alpha \cdot E[p(\alpha | y)] \cdot dx \\
 &= \int \alpha \cdot \left[\underbrace{\int p(\alpha | y) \cdot p(y) dy}_{p(y|\alpha) \cdot p(\alpha)} \right] dx \quad \text{Bayes} \\
 &= \int \alpha \cdot \left[\int p(y|\alpha) \cdot p(\alpha) dy \right] dx \\
 &= \int \alpha \cdot p(\alpha) \underbrace{\left[\int p(y|\alpha) dy \right]}_1 dx \\
 &= \int \alpha \cdot p(\alpha) dx = E[\alpha]
 \end{aligned}$$

recuerda:
valor medio de x
 $E[x] = \int x p(x) dx$

$$E[g(x)] = \int g(x) p(x) dx$$

Estimación lineal de señales

Vamos a trabajar con → Procesos estocásticos (señales!)
→ Estimadores lineales

$$y(n) = s(n) + w(n)$$

↓ ↓
señal ruido

- $\{\tilde{s}(n)\}$ proceso estacionario en sentido amplio
 $E[\tilde{s}(n+m) \cdot s(n)] = R_{ss}(m)$
y con media nula $E[\tilde{s}(n)] = 0$
(si no lo fuera, se le resta y ya está)

- $\{\tilde{w}(n)\}$ proceso estacionario en sentido amplio
 $E[\tilde{w}(n+m) \cdot w(n)] = R_{ww}(m)$
y con media nula $E[\tilde{w}(n)] = 0$
- La señal y el ruido son incorrelados
 $E[\tilde{w}(n+m) \cdot \tilde{s}(n)] = R_{ws}(m) = 0$

Problema: Estimar $s(n+k) \equiv s$
a partir de $y = [y(n), y(n-1), \dots, y(n-N+1)]$

si $k=0 \rightarrow$ filtrado → eliminar el ruido

$k > 0 \rightarrow$ filtrado + predicción

$k < 0 \rightarrow$ filtrado + interpolación → intento reconstruir muestras que me faltan en el pasado


y quiero que sea un procesado LINEAL

$$\hat{s}(n+k) = \underline{h}^T \underline{y} \quad \rightarrow \text{Es un filtro FIR}$$

$y \xrightarrow{h} \hat{s}$

hay que encontrar esta h

para cada instante n es un vector que va cambiando (con las N muestras anteriores)



Error cuadrático medio

$$ECM = E[(s - \underline{h}^T \underline{y})^2]$$

$$= E[s^2 - 2s\underline{h}^T \underline{y} + \underline{h}^T \underline{y} \underline{y}^T \underline{h}]$$

NOTA:

$\underline{h}^T \underline{y}$ no es más que un número

$\underline{h}^T \underline{y} \underline{y}^T \underline{h}$ no es más que ese número al cuadrado. He cambiado los traspuestos porque me conviene y el producto escalar es conmutativo

$$\text{Entregue} + (d+n)^2 =$$

$$\text{Entregue} + d^2 + n^2$$

$$= E[s^2] - 2\underline{h}^T E[\underline{s}\underline{y}] + \underline{h}^T E[\underline{y}\underline{y}^T] \underline{h}$$

un vector de valores medios

matriz NXN


indagaremos en ambos

$$E[\underline{y}\underline{y}^T] = \underline{R}_{yy} \longrightarrow R_{yy}(i,j) = E[y(i) \cdot y(j)] = E[y(n-i+1)y(n-j+1)]$$

la comp.
(i,j) de la matriz

$$= R_{yy}(j-i)$$

La matriz de autocorrelación puede construirse conociendo la función de autocorrelación del proceso estocástico $y(n)$



$$E[s \cdot \underline{y}] = \underline{R}_{sy} \longrightarrow R_{sy}(i) = E[s(n+k)y(n-i+1)]$$

podemos quitar la parte del ruido de la y ya que es incorrelado cons

$$= E[s(n+k) \cdot s(n-i+1)]$$

a la correlación sólo le importa la diferencia de índices

$$= R_{ss}(k+i-1)$$

$$ECM = E[s^2] - 2\underline{h}^T \underline{R}_{sy} + \underline{h}^T \underline{R}_{yy} \underline{h}$$

Nos interesa minimizar el ECM, por tanto derivamos

(con Reglas de derivación con matrices y vectores)
se resuelve muy fácilmente

$$\frac{\partial \text{ECM}}{\partial \underline{h}} = \begin{bmatrix} \frac{\partial \text{ECM}}{\partial h(1)} \\ \vdots \\ \frac{\partial \text{ECM}}{\partial h(n)} \end{bmatrix} = -2 \underline{R}_{sy} + 2 \underline{R}_{yy} \underline{h} = 0$$

Igualando $\frac{\partial \text{ECM}}{\partial \underline{h}}$ a cero se obtiene un sistema de ecuaciones lineales que se resuelve con:

$$\underline{h} = \underline{R}_{yy}^{-1} \underline{R}_{sy}$$

Ecuaciones de Wiener-Hopf

Ésta es la solución lineal óptima

Además si todo es gaussiano resulta que coincide esta solución con las soluciones MAP, ML, ... $p(\alpha|y)$

Ejemplo: Predecir el valor de un proceso estacionario (sin ruido) (por ej. predecir la bolsa)

Ejemplo 6: construir el predictor lineal óptimo (ECM mínimo) de $s(n+1)$ a partir de $s(n)$

$$w(n) = 0 \rightarrow R_{ww}(m) = 0 \quad s \equiv s(n+1)$$

$$\underline{y} = [s(n)]^T = s(n)$$

nota de campo:
algunos que trabajan en esto dicen que una matriz es mínima
 1000×1000 . Cualquier
matriz menor que
eso lo consideran
un escalar ...

La matriz de autocorrelación

$$\underline{R}_{yy} = \underline{R}_{ss} = R_{ss}(0)$$

matriz
tamaño 1 escalar

vector de correlación señal

$$\underline{R}_{sy} = E[s(n+1)s(n)] = R_{ss}(1)$$


$$\left. \begin{array}{l} \underline{h} = h = \frac{R_{ss}(1)}{R_{ss}(0)} = p \\ \text{es decir} \end{array} \right\}$$

$$s(n) \xrightarrow[p]{} \hat{s}(n+1)$$

si $p=1 \rightarrow$ mucha correlación entre n y $n+1$
(tomo el valor anterior)


si $p=0 \rightarrow$ no tengo ni idea así que digo
que es la media

si emparejo muestras contiguas.



Forma sencilla experimental
de hacer un predictor con $N=1$

Puedo calcular la media alrededor de ventanas de $s(n)$



Problema 1

E estadística

Tengo un conjunto de números binarios

x_0, x_1, \dots, x_{N-1} independientes

MUY IMPORTANTE

$$\text{Prob}\{x_i = 1\} = \theta \quad \forall i$$

$$\text{Hallar } \hat{\theta}_{ML} \rightarrow \hat{\theta}_{ML} = \max_{\theta} p(\underline{x} | \theta)$$

calculemos:

$$p(\underline{x} | \theta) = \prod_{i=0}^{N-1} p(x_i | \theta)$$

$$p(x_i | \theta) = \begin{cases} 1-\theta & x_i=0 \\ \theta & x_i=1 \end{cases} = \theta^{x_i} \cdot (1-\theta)^{1-x_i}$$

↑ compactando **i**

Por tanto:

$$p(\underline{x} | \theta) = \prod_{i=0}^{N-1} \theta^{x_i} \cdot (1-\theta)^{1-x_i}$$

$$= \theta^k \cdot (1-\theta)^{N-k}$$

siendo k el número de unos

$$k = \sum_{i=0}^{N-1} x_i$$

↓ en ① muy aconsejable aplicar el ln para simplificar

$$\ln p(\underline{x} | \theta) = k \ln \theta + (N-k) \ln (1-\theta)$$

Maximizándolo:

$$\begin{aligned} \frac{\partial \ln p(\underline{x} | \theta)}{\partial \theta} &= \frac{k}{\theta} - (N-k) \frac{1}{1-\theta} \\ &= \frac{k(1-\theta) - (N-k)\theta}{\theta(1-\theta)} = 0 \end{aligned}$$

$$\Rightarrow k(1-\theta) - (N-k)\theta = 0$$

$$\Rightarrow \hat{\theta}_{ML} = \frac{k}{N}$$

Esto es cierto y sencillo gracias a que los x_i son independientes
(ej: intención de voto: PP o PSOE?
... si siempre pregunta al mismo....)

Problema 3

$$x_0, \dots, x_{M-1}$$

independientes

$$p(x_i | \theta) = \theta e^{-\theta x_i} \quad E[x_i] = \frac{1}{\theta}$$

$$(x_i \geq 0, \theta \geq 0)$$

- calcular $\hat{\theta}_{ML}$
- calcular $\hat{\theta}_{MAP}$ suponiendo $p(\theta) = \lambda e^{-\lambda \theta} \quad \lambda \geq 0$

• ¿ $\hat{\theta}_{ML}$? $\hat{\theta}_{ML} = \max_{\theta} p(\underline{x} | \theta)$

$$p(\underline{x} | \theta) = \prod_{i=0}^{M-1} p(x_i | \theta) = \prod_{i=0}^{M-1} \theta e^{-\theta x_i} = \theta^M e^{-k\theta} \quad \text{siendo } k = \sum_i x_i$$

Hay que buscar el máximo.

Puede ser más sencillo tomando la función logarítmica

$$\ln p(\underline{x} | \theta) = M \ln \theta - k\theta$$

$$\frac{\partial \ln p(\underline{x} | \theta)}{\partial \theta} = \frac{M}{\theta} - k = 0$$

$$\Rightarrow \hat{\theta}_{ML} = \frac{M}{k} = \frac{1}{\frac{1}{M} \sum_{i=0}^{M-1} x_i}$$

lo cual es lógico ya que
teníamos $E[x_i] = \frac{1}{\theta}$

la inversa
de la media

• ¿ $\hat{\theta}_{MAP}$? $\hat{\theta}_{MAP} = \max_{\theta} p(\theta | \underline{x})$

$$= \max_{\theta} p(\underline{x} | \theta) \cdot p(\theta)$$

$$= \max_{\theta} \left[\prod_{i=0}^{M-1} p(x_i | \theta) \right] \cdot (\lambda e^{-\lambda \theta}) = \max_{\theta} [\theta^M e^{-k\theta}] \cdot (\lambda e^{-\lambda \theta})$$

tomando logaritmo neperiano para maximizar más fácil

$$\ln [p(\underline{x} | \theta) \cdot p(\theta)] = M \ln \theta - k\theta + \ln \lambda - \lambda \theta$$

$$\frac{\partial \ln [p(\underline{x} | \theta) \cdot p(\theta)]}{\partial \theta} = \frac{M}{\theta} - k - \lambda$$

$$\Rightarrow \hat{\theta}_{MAP} = \frac{M}{k + \lambda}$$

se ha corregido el valor anterior a partir del conocimiento del parámetro

si $\lambda \rightarrow 0$ se tiende a una varianza muy grande en la V.A. θ

$$p(\theta) = \lambda e^{-\lambda \theta} \rightarrow E[\theta] = \frac{1}{\lambda} \rightarrow \text{var}[\theta] = \frac{1}{\lambda^2}$$

una varianza muy grande no aporta información

Problema 4

x_0, \dots, x_{M-1} independientes


x_i uniforme entre $-\frac{\Delta}{2}, \frac{\Delta}{2}$

- Hallar $\hat{\Delta}_{ML}$

- Hallar $\hat{\Delta}_{MAP}$ sabiendo $p(\Delta) = \lambda e^{-\lambda\Delta}$

- ¿ $\hat{\Delta}_{ML}$?

Vamos a poner la distribución de cada x_i



$$\rightarrow p(x_i / \Delta) = \frac{1}{\Delta} \text{rect}\left(\frac{x_i}{\Delta}\right)$$

$$\hat{\Delta}_{ML} = \max_{\Delta} p(\underline{x} | \Delta)$$

$$= \max_{\Delta} \prod_{i=0}^{M-1} p(x_i / \Delta)$$

$$= \max_{\Delta} \frac{1}{\Delta^M} \cdot \prod_{i=0}^{M-1} \text{rect}\left(\frac{x_i}{\Delta}\right)$$

En lugar de derivar vamos a ver si encontramos el máximo razonando

$$p(\underline{x} | \Delta) = \begin{cases} 0 & \text{si } |x_i| > \frac{\Delta}{2} \text{ en algún } x_i \text{ (basta con uno)} \\ \frac{1}{\Delta^M} & \text{si } |x_i| < \frac{\Delta}{2} \quad \forall x_i \leftarrow \text{i.e. todo el vector} \end{cases}$$

me interesaría Δ muy pequeño para tener valor muy alto pero no lo suficiente como para anular algún x_i !!!

Cogeremos el mínimo posible siempre y cuando $\Delta/2$ esté por encima de todos los x_i

$$\Rightarrow \hat{\Delta}_{ML} = \max_i 2|x_i|$$



Nota: y si no supiéramos que la j.d.p. es simétrica, cogeríamos entre el mínimo y el máximo

lógicamente coger un Δ menor sería estúpido
(tratamos de estimar la j.d.p. de x_i viendo sus muestras)

- $$\hat{\Delta}_{MAP} = \max_{\Delta} p(\underline{x} | \Delta) p(\Delta)$$

$$= \max_{\Delta} \left[\frac{1}{\Delta^M} \prod_{i=0}^{M-1} \text{rect}\left(\frac{x_i}{\Delta}\right) \right] \cdot \lambda e^{-\lambda \Delta}$$

$$= \max_{\Delta} \begin{cases} 0 & \text{si } |x_i| > \frac{\Delta}{2} \text{ en algún } x_i \\ \lambda e^{-\lambda \Delta} \cdot \frac{1}{\Delta^M} & \text{si } |x_i| < \frac{\Delta}{2} \forall x_i \end{cases}$$

este conocimiento no nos ha aportado nada ya que nos sigue pidiendo que busquemos el valor más pequeño posible de Δ (siempre y cuando entren dentro todas las observaciones)

$$\Rightarrow \hat{\Delta}_{MAP} = \max_{\Delta} 2|x_i|$$

Notice that $\lim_{n \rightarrow \infty} \frac{a_n}{n} = L$ if and only if $\lim_{n \rightarrow \infty} \frac{a_n - L}{n} = 0$.

Problema 2

x_0, \dots, x_{M-1} independientes

$$p(x_i | \theta) = e^{-\theta} \cdot \frac{1}{x_i!} \theta^{x_i} \quad \begin{array}{l} \text{Distribución} \\ \text{de Poisson} \end{array}$$

$$x_i = 0, 1, 2, 3, \dots$$

- Hallar $\hat{\theta}_{ML}$
- Indicar si $\hat{\theta}_{ML}$ es eficiente

$$\bullet p(\underline{x} | \theta) = \prod_{i=0}^{M-1} p(x_i | \theta) = \frac{e^{-M\theta}}{\prod_{i=0}^{M-1} x_i!} \theta^k \quad k = \sum_{i=0}^{M-1} x_i$$

$$\ln p(\underline{x} | \theta) = -M\theta - \ln \left(\prod_{i=0}^{M-1} x_i! \right) + k \ln \theta$$

Hay que hallar el máximo

$$\frac{\partial \ln p(\underline{x} | \theta)}{\partial \theta} = -M + \frac{k}{\theta}$$

$$\Rightarrow \hat{\theta}_{ML} = \frac{k}{M} = \frac{1}{M} \sum x_i$$

la estimación de θ es la media muestral.

Tiene sentido ya que el valor medio de una distribución Poisson

$$p(x_i) = e^{-\theta} \cdot \frac{1}{x_i!} \theta^{x_i} \rightarrow E[x_i] = \theta$$

• Para hallar si es eficiente, hay que hallar la cota de Kramer-Rao, la cual sólo existe si el estimador es insesgado

$$\bullet \text{¿es insesgado? } E[\hat{\theta}_{ML}] = E\left[\frac{1}{M} \sum_{i=0}^{M-1} x_i\right] = \frac{1}{M} \sum_{i=0}^{M-1} E[x_i] = \frac{1}{M} \cdot M\theta = \theta$$

• ¿varianza del estimador?

$$\text{var}[\hat{\theta}_{ML}] = E[(\hat{\theta}_{ML} - \theta)^2] = E[\hat{\theta}_{ML}^2] - 2E[\hat{\theta}_{ML} \cdot \theta] + E[\theta^2]$$

ya que no tenemos info de θ , para nosotros es una constante

$$= E[\hat{\theta}_{ML}^2] - 2\theta \underbrace{E[\hat{\theta}_{ML}]}_{\theta} + \theta^2$$

$$= E[\hat{\theta}_{ML}^2] - \theta^2$$

Podríamos haber llegado usando $E[x^2] = E^2[x] + \text{var}[x]$

↓
falta hallar este término
(valor cuadrático medio)

$$\begin{aligned}
 E[\hat{\theta}_{ML}^2] &= \frac{1}{M^2} E\left[\left(\sum x_i\right)^2\right] \xrightarrow{\text{se puede hacer con sumatorios e integrales}} \\
 &= \frac{1}{M^2} E\left[\sum_{n=0}^{M-1} \sum_{m=0}^{M-1} x_n \cdot x_m\right] \\
 &= \frac{1}{M^2} \sum_n \sum_m E[x_n \cdot x_m], \\
 &\quad \left. \begin{array}{l} E[x_n^2] \text{ si } m=n \leftarrow M \text{ casos} \\ E[x_n x_m] \text{ si } m \neq n \leftarrow M^2 - M \text{ casos} \end{array} \right) \\
 &= \frac{1}{M^2} \left(\sum_{n=0}^{M-1} E[x_n^2] + \sum_{n=0}^{M-1} \sum_{m \neq n} E[x_n] \cdot E[x_m] \right) \\
 &= \frac{1}{M^2} \left(M \cdot E[x_n^2] + (M^2 - M) E^2[x_n] \right)
 \end{aligned}$$

i) al ser independientes, $E[x_i x_j] = E[x_i] \cdot E[x_j]$

$\sum E[x_i] = M \cdot E[x_i]$
 $\sum \sum E[x_i] \cdot E[x_j] = \sum E^2[x_i] = (M^2 - M) E^2[x_i]$

Sabiendo que, para x_i de Poisson se tiene

$$\begin{aligned} E[x_i] &= \theta \\ E[x_i^2] &= \theta \end{aligned}$$

$$= \frac{1}{M^2} \cdot M \cdot \theta + \frac{1}{M^2} M(M-1) \cdot \theta^2 = \frac{\theta}{M} + \frac{M-1}{M} \theta^2$$

Por tanto ya sabemos:

$$E[\hat{\theta}_{ML}] = \frac{\theta}{M} + \frac{M-1}{M} \theta^2$$

$$\text{var}[\hat{\theta}_{ML}] = \frac{\theta}{M} + \frac{M-1}{M} \theta^2 - \theta^2$$

Por tanto:

$$\text{CCR} = \frac{-1}{E\left[\frac{\partial^2 p(x/\theta)}{\partial \theta^2}\right]} = \frac{1}{E\left[\frac{\delta(-M + \frac{k}{\theta})}{\partial \theta}\right]} = \frac{1}{E\left[\frac{k}{\theta^2}\right]}$$

i) no olvidar aplicar $E[\cdot]$

$$= \frac{1}{E\left[\frac{\sum x_i}{\theta^2}\right]} = \frac{\theta^2}{M\theta} = \frac{\theta}{M}$$

Por lo tanto el estimador es asintóticamente eficiente (cuando $M \rightarrow \infty$)

DETECCIÓN

TEORÍA DE LA DETECCIÓN: BIBLIOGRAFÍA

[1] M.D. Srinath, P.K. Rajasekaran, ... "Introduction to statistical signal processing with applications" (Capítulo 3) Ed. Prentice Hall


[2] Hippelstiel, Ralph Dieter: "Detection theory: applications and digital signal processing"

Índice

1. Introducción
2. Test de Hipótesis
3. Criterios de decisión
 - 3.1. Criterio de mínima probabilidad de error
 - 3.2. Criterio minimax
 - 3.3. Test de Neyman Pearson
 - 3.4. Detección Máxima a posteriori (MAP)
 - 3.5. Criterio de máxima verosimilitud (ML)
4. Hipótesis Múltiples
5. Test de múltiples hipótesis
6. Test de hipótesis compuestas

1. Introducción

- Deseamos elegir entre varias situaciones de manera automática
- Seleccionar la opción correcta




La observación es una V.A.


(ya que la distorsión y el ruido no lo conocemos)

2. Test de Hipótesis

La detección y la clasificación son problemas que resolvemos aplicando Test de Hipótesis



- Z : región de los valores posibles de z
- En Test de Hipótesis binario se divide en dos zonas Z_0 y Z_1



$$Z = Z_0 \cup Z_1$$

$$Z_0 \cap Z_1 = \emptyset$$

regiones de decisión

De forma que decidimos la hipótesis según a qué región pertenezca z

$$\begin{aligned} z \in Z_0 &\rightarrow H_0 \\ z \in Z_1 &\rightarrow H_1 \end{aligned}$$

Se necesita conocer la fdp de z para cada hipótesis $H_0 \rightarrow f_0(z)$
 $H_1 \rightarrow f_1(z)$

ejemplo:

vector de observaciones $\underline{z} = (z_0, z_1, \dots, z_N)$

Nos dan información de cada observación z_i

iid (independientes e idénticamente distribuidas)

no hay juego: $H_0 \rightarrow z_i$ tiene fdp gaussiana $f_G(z_i) \rightarrow p(z_0, z_1, \dots, z_N | H_0) = \prod_{i=1}^N f_G(z_i)$
sí hay juego: $H_1 \rightarrow z_i$ tiene fdp laplaciana $f_L(z_i) \rightarrow p(\underbrace{z_0, z_1, \dots, z_N}_{\underline{z}} | H_1) = \prod f_L(z_i)$

¿con qué criterio escoges las regiones?

suele reducirse el problema a escoger un umbral

ejemplo : Test de Hipótesis Compuesto

z_1, z_2, \dots, z_N iid gaussianas con media θ y varianza 1

$$H_1 \rightarrow \theta = 0 \rightarrow p(\underline{z} | H_1) = \prod_{i=1}^N N(0, 1) = \frac{1}{(\sqrt{2\pi})^N} e^{-\sum_{i=1}^N \frac{z_i^2}{2}}$$

$H_0 \rightarrow \theta \neq 0$ (Test de Hipótesis compuesto)

¿Cuál será la fdp en ese caso?

↓
ii Yo no sé cuál será la media
de los z_i en ese caso!!

$$p(\underline{z} | H_1) = \prod_{i=1}^N N(\theta, 1)$$

↑
todas las z_i tendrán la
misma θ , pero yo no
se cuál es.

previamente tendré que estimar θ
(teoría de la estimación)

recuerda

$$N(m, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-m)^2}{2\sigma^2}}$$

comprueba

3. Criterios de decisión

3.1 criterio MAP que nos dice el sentido común

$$\text{si } p(H_0 | z) > p(H_1 | z) \rightarrow H_0$$

$$\Leftrightarrow \frac{p(H_1 | z)}{p(H_0 | z)} \stackrel{H_1}{\geq} 1$$

criterio
MAP

$$\text{si } p(H_1 | z) > p(H_0 | z) \rightarrow H_1$$

↑
¿cómo podemos conocer esto?

Por Bayes: $p(H_i | z) = \frac{p(z | H_i) \cdot p(H_i)}{p(z)}$

Por tanto

$$\frac{p(z | H_1)}{p(z | H_0)} \stackrel{H_1}{\geq} \frac{p(H_1)}{p(H_0)}$$

$$\Lambda(z) \geq \lambda_{\text{umbral}}$$

razón de verosimilitud



ejemplo:

Canal de comunicaciones:

Fuente: T segundos $\xrightarrow{0} \begin{cases} 1 \\ 0 \end{cases}$

canal: Añade ruido $v(t) \rightarrow$ gaussiana media nula varianza uno

Recibido: $r(t) = \begin{cases} 1 + v(t) \\ v(t) \end{cases}$ en T segundos

Con una sola observación decidir H_0 o H_1

$$H_0: z = v$$

$$H_1: z = 1 + v$$

Podemos deducir

$$\bullet p(z|H_0) = p(v) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

$\bullet p(z|H_1)$: será también gaussiana pero con la media desplazada

$$E[z] = E[1+v] = E[1] + E[v] = 1$$

$$\text{var}[z] = E[(z-1)^2] = E[v^2] = 1$$

$$p(z|H_1) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(z-1)^2}{2}}$$

Por lo tanto podemos calcular


$$\Lambda(z) = \frac{p(z|H_1)}{p(z|H_0)} = \frac{e^{-\frac{(z-1)^2}{2}}}{e^{-\frac{z^2}{2}}} = e^{z-\frac{1}{2}}$$

$$\lambda = \frac{p(H_0)}{p(H_1)}$$

$$\boxed{e^{z-\frac{1}{2}} \stackrel{\substack{H_1 \\ H_0}}{\geq} \frac{p(H_0)}{p(H_1)}}$$

↓ tomando ln

$$\boxed{z \geq \frac{1}{2} + \ln\left(\frac{p(H_0)}{p(H_1)}\right)}$$



El principal problema es obtener la fdp. bajo cada hipótesis

• Criterio de Bayes

Vamos a tener en cuenta el coste que supone equivocarse, y vamos a minimizar el coste.

Llamamos D_i a la decisión tomada $i=0,1$

$D_0 \text{ ó } D_1$ según creemos que la hipótesis es H_0 ó H_1

Pueden pasar 4 cosas:

1. H_0 hipótesis verdadera y decidimos $D_0 \rightarrow p(H_0, D_0)$ } aciertos
2. H_1 hipótesis verdadera y decidimos $D_1 \rightarrow p(H_1, D_1)$ } C_{10}
3. H_0 hipótesis verdadera y decidimos $D_1 \rightarrow p(H_0, D_1) \rightarrow$ falsa alarma
4. H_1 hipótesis verdadera y decidimos $D_0 \rightarrow p(H_1, D_0) \rightarrow$ pérdida (miss)

prob conjunta
intersección

cada decisión tendrá
un coste según el
contexto.


C_{ij} : coste de ser la hipótesis " j " verdadera
y nosotros haber decidido " i "

Vamos a intentar minimizar el coste medio \bar{C}

$$\bar{C} = C_{00} \cdot p(H_0, D_0) + C_{11} \cdot p(H_1, D_1) + C_{10} \cdot p(H_0, D_1) + C_{01} \cdot p(H_1, D_0)$$

Por Bayes: $p(D_i | H_j) = \frac{p(D_i, H_j)}{p(H_j)}$

$$\bar{C} = C_{00} \cdot p(H_0) \cdot p(D_0 | H_0) + C_{11} \cdot p(H_1) \cdot p(D_1 | H_1) + C_{10} \cdot p(H_0) \cdot p(D_1 | H_0) + C_{01} \cdot p(H_1) \cdot p(D_0 | H_1)$$



Es fácil ver que:

$$p(D_i | H_j) = \int_{Z_i} p(z | H_j) dz$$

Además, puesto que $Z = Z_0 \cup Z_1$ y $Z_0 \cap Z_1 = \emptyset$

$$\int_Z p(z | H_j) dz = 1 = \int_{Z_0} p(z | H_j) dz + \int_{Z_1} p(z | H_j) dz$$

$$\Rightarrow \int_{Z_1} p(z | H_j) dz = 1 - \int_{Z_0} p(z | H_j) dz$$

Por lo tanto se deduce que podemos expresarlo todo en función de la integral en una única zona:

$$\bar{C} = C_{00} \cdot p(H_0) \cdot \int_{z_0} p(z|H_0) dz$$

$$+ C_{11} p(H_1) \cdot \left[1 - \int_{z_0} p(z|H_1) dz \right]$$

$$+ C_{10} p(H_0) \cdot \left[1 - \int_{z_0} p(z|H_0) dz \right]$$

$$+ C_{01} p(H_1) \cdot \int_{z_0} p(z|H_1) dz$$

$$\bar{C} = \underbrace{C_{11} p(H_1) + C_{10} p(H_0)}_{\text{cantidad fija} \quad (\text{viene de los unos})} + \underbrace{\int_{z_0} p(H_1) \cdot (C_{01} - C_{11}) p(z|H_1) - p(H_0) (C_{10} - C_{00}) p(z|H_0) dz}_{\text{minimizar esto} \quad (\text{puede ser negativo})}$$

Nuestro criterio será:

$$p(H_1) \cdot (C_{01} - C_{11}) \frac{p(z|H_1)}{p(z|H_0)} \geq p(H_0) \cdot (C_{10} - C_{00}) \frac{p(z|H_0)}{p(z|H_1)}$$

que queda como:

$$\frac{p(z|H_1)}{p(z|H_0)} \geq \frac{C_{10} - C_{00}}{C_{01} - C_{11}} \cdot \frac{p(H_0)}{p(H_1)}$$

$$\Lambda(z) \geq -\lambda$$

criterio de Bayes



expresando λ

$$sb(H_1|z) q \geq sb(H_0|z) q$$

$$\lambda = \sqrt{D} \cdot \sqrt{V} \cdot \sqrt{s} \approx \sqrt{D} \cdot \sqrt{V} \cdot \sqrt{s}$$

$$sb(H_1|z) q + sb(H_0|z) q = t = sb(H|z) q$$

$$sb(H_1|z) q - t = sb(H_0|z) q \Leftrightarrow$$

Ejercicio: Una fuente emite señales con 2 posibles varianzas

$F \rightarrow$ señal fdp gaussiana mediquo=0

H_1 : varianza σ_1^2 $\sigma_1^2 > \sigma_0^2$

H_0 : varianza σ_0^2

Hay que hallar:

$$p(z|H_0) = N(0; \sigma_0^2) = \frac{1}{\sqrt{2\pi}\sigma_0} \exp\left(-\frac{z^2}{2\sigma_0^2}\right)$$

$$p(z|H_1) = N(0; \sigma_1^2) = \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left(-\frac{z^2}{2\sigma_1^2}\right)$$

Por tanto:

$$\Lambda(z) = \frac{p(z|H_1)}{p(z|H_0)} = \frac{\sigma_0}{\sigma_1} \exp\left(-\frac{1}{2}z^2\left(\frac{1}{\sigma_1^2} - \frac{1}{\sigma_0^2}\right)\right)$$

Aplicando la regla de decisión (con el ln) se obtiene

$$\ln \Lambda(z) \stackrel{H_1}{\geq} \ln \lambda \quad \lambda = \frac{c_{10} - c_{00}}{c_{01} - c_{11}} \cdot \frac{P(H_0)}{P(H_1)}$$

$$\ln\left(\frac{\sigma_0}{\sigma_1}\right) - \frac{1}{2}z^2\left(\frac{1}{\sigma_1^2} - \frac{1}{\sigma_0^2}\right) \stackrel{H_1}{\geq} \ln \lambda$$

$$\frac{1}{2}z^2\left(\frac{\sigma_1^2 - \sigma_0^2}{\sigma_1^2 \cdot \sigma_0^2}\right) \stackrel{H_1}{\geq} \ln \lambda - \ln\left(\frac{\sigma_0}{\sigma_1}\right)$$

si z era
gaussiana,
esta será
chi-cuadrado

$$z^2 \stackrel{H_1}{\geq} \underbrace{\frac{2\sigma_1^2\sigma_0^2}{\sigma_1^2\sigma_0^2} \ln\left(\frac{\sigma_1}{\sigma_0}\lambda\right)}_{\text{umbral } \gamma}$$

$$z^2 \stackrel{H_1}{\geq} \gamma$$

¿Cómo es de bueno el sistema?

P_F Probabilidad de falsa alarma $P_I = \Pr(D_1|H_0) = \int_{Z_1} p(z|H_0) dz = \int_{\gamma}^{\infty} p(\Lambda(z)|H_0) dz$

P_M Probabilidad de pérdida (miss) $P_{II} = \Pr(D_0|H_1) = \int_{Z_0} p(z|H_1) dz = \int_{-\infty}^{\gamma} p(\Lambda(z)|H_1) dz$

Probabilidad de error

$$P_e = P_I \cdot p(H_0) + P_{II} \cdot p(H_1)$$

P_F, P_M no tienen en cuenta $p(H_0)$ frente a $p(H_1)$.
Pero sí

Probabilidad de detección

$$P_D = \Pr(D_1|H_1)$$

Sabemos que el criterio de Bayes es óptimo, pero se requiere conocer ciertos datos.

Hay otros criterios (ya no óptimos) que necesitan menos datos

Criterio de mínima probabilidad de error

Supone $C_{00} = C_{11} = 0$ (observador ideal)
 $C_{10} = C_{01} = 1$

$$\hookrightarrow \lambda = \frac{P(H_0)}{P(H_1)} \rightarrow \begin{array}{l} \text{Equivale al MAP} \\ \text{Requiere conocer las} \\ \text{prob. a priori} \end{array}$$

El coste medio

$$\begin{aligned} \bar{C} &= C_{00}(1-P_F) + C_{10}P_F + p(H_1) \cdot [(C_{11}-C_{00}) + (C_{01}-C_{11})P_M - (C_{10}-C_{00})P_F] \\ &= P_F + p(H_1) \cdot [P_M - P_F] \\ &= P_F(1-p(H_1)) + p(H_1)P_M \\ &= P_F p(H_0) + P_M p(H_1) \\ &= Pe \end{aligned}$$

El coste medio es igual a la prob. de error

Ejemplo: $H_1 : m+n$

$H_0 : n$ ruido $N(0, \sigma^2)$

Determinar la regla de decisión aplicando el criterio de mínima probabilidad de error, sabiendo $p(H_0) = p(H_1) = 0.5$

$$\Lambda(z) = \frac{p(z|H_1)}{p(z|H_0)} = \frac{N(m, \sigma^2)}{N(0, \sigma^2)} = \frac{\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(z-m)^2}{2\sigma^2}\right)}{\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{z^2}{2\sigma^2}\right)} = \exp\left(-\frac{(z-m)^2}{2\sigma^2} + \frac{z^2}{2\sigma^2}\right)$$

Por tanto el criterio queda

$$\Lambda(z) \stackrel{H_1}{\underset{H_0}{>}} \frac{p(H_0)}{p(H_1)} = 1$$

en

$$-\frac{z^2 + 2mz - m^2 + z^2}{2\sigma^2} \stackrel{H_1}{\underset{H_0}{\geq}} 0$$

$$z \stackrel{H_1}{\underset{H_0}{\geq}} \frac{m}{2}$$

Típicamente se normaliza z


$$\bar{z} = z/\sigma$$

para que $p(\bar{z}|H_1) = N(d, 1)$

$$p(\bar{z}|H_0) = N(0, 1)$$

$$\bar{z} \stackrel{H_1}{\underset{H_0}{\geq}} \frac{m}{2\sigma} = \frac{d}{z}$$


$$d = \frac{m}{\sigma}$$



Criterio minimax

Se aplica cuando no conocemos las probabilidades a priori

$$\text{Recuerda: } \bar{C} = C_{00}(1-P_F) + C_{10}P_F + p(H_1)[(C_{11}-C_{00}) + (C_{01}-C_{11})P_M - (C_{10}-C_{00})P_F]$$



El criterio minimax supone que
 $p(H_1) = p_1^*$

$$p_1^* \text{ se obtiene maximizando } \bar{C}$$

$$\frac{d\bar{C}}{dp(H_1)} = 0$$

$$= (C_{11}-C_{00}) + (C_{01}-C_{11})P_M - (C_{10}-C_{00})P_F$$

Si además no conocemos los costes
y suponemos $C_{00}=C_{11}=0$
 $C_{01}=C_{10}=1$

$$\frac{d\bar{C}}{dp(H_1)} = P_M - P_F = 0$$

$$\Rightarrow P_M = P_F$$

• Criterio de Neyman-Pearson

X. Criterio de Neyman-Pearson

→ C_{ij} desconocidos

→ $p(H_i)$ desconocidas

¿Puedo minimizar a la vez $P_F = \alpha$ y $P_M = \beta$?

Neumann vio que no se puede minimizar ambas.

Se le ocurrió:

fijar $P_F = \alpha \rightarrow$ minimizar P_M
 (maximizar P_D)

Pudo hacerlo con Multiplicadores de Lagrange

$$J = P_M + \lambda(P_F - \alpha)$$

$$J = \int_{z_0}^{\infty} p(z|H_1) dz + \lambda \left(\int_{z_1}^{\infty} p(z|H_0) dz - \alpha \right)$$

$$= \int_{z_0}^{\infty} p(z|H_1) dz + \lambda \left([1 - \int_{z_0}^{\infty} p(z|H_0)] - \alpha \right)$$

$$= \lambda(1-\alpha) \int_{z_0}^{\infty} [p(z|H_1) - \lambda p(z|H_0)] dz$$

Puedo escoger el λ que minimice J condicionada a la decisión sin más que hacer:

$$p(z|H_1) \stackrel{H_1}{\underset{H_0}{\geq}} p(z|H_0) \lambda \Rightarrow \frac{p(z|H_1)}{p(z|H_0)} \stackrel{H_1}{\underset{H_0}{\geq}} \lambda \leftarrow \text{el umbral de Neyman-Pearson}$$

Es decir, hay que resolver la ecuación:

$$\int_{z_0}^{\infty} p(z|H_0) dz = \alpha$$

↑
prob. de falsa alarma (dato)
(exijimos un valor)

↑
umbral que debemos determinar

Hipótesis múltiple

- Supongamos $M \geq 2$ eventos H_0, H_1, \dots, H_{M-1}

Asumimos:

- $p(H_0), p(H_1), \dots, p(H_{M-1})$ conocidos ($\sum p_i = 1$)
- C_{ij} es el coste de D_i / H_j
- $p(z | H_i)$

- El objetivo de decisión es minimizar el coste medio \bar{C}

$$\bar{C} = \sum_{i=0}^{M-1} \sum_{j=0}^{M-1} C_{ij} \cdot P(H_j) \cdot P(D_i | H_j)$$

Sabiendo que $P(D_i | H_j) = \int_{Z_i} p(z | H_j) dz$

siendo Z_i la región de decisión de H_i

$$Z = \bigcup_{i=0}^{M-1} Z_i$$

$$Z_i \cap Z_j = \emptyset \quad \forall i \neq j$$

$$\bar{C} = \sum_{i=0}^{M-1} C_{ii} P(H_i) \int_{Z_i} p(z | H_i) dz + \sum_{\substack{j=0 \\ j \neq i}}^{M-1} C_{ij} P(H_j) \int_{Z_j} p(z | H_j) dz$$

y puesto que: $\int_{Z_i} p(z | H_i) dz = 1 - \sum_{\substack{j=0 \\ j \neq i}}^{M-1} \int_{Z_j} p(z | H_j) dz$

$$\bar{C} = \underbrace{\sum_{i=0}^{M-1} C_{ii} P(H_i)}_{\text{coste fijo} \atop \text{(no depende} \atop \text{de } Z_i)} + \underbrace{\sum_{i=0}^{M-1} \int_{Z_i} \sum_{\substack{j=0 \\ j \neq i}}^{M-1} P(H_j) (C_{ij} - C_{jj}) P(z | H_j) dz}_{\text{coste variable}}$$

Escogeremos las regiones Z_i que minimicen

minimizar: $I_i(z) = \sum_{\substack{j=0 \\ j \neq i}}^{M-1} P(H_j) (C_{ij} - C_{jj}) P(z | H_j)$ (sin referencia)

tomando referencia $p(z | H_0)$

$$J_i(z) = \frac{I_i(z)}{P(z | H_0)} = \sum_{\substack{j=0 \\ j \neq i}}^{M-1} P(H_j) \cdot (C_{ij} - C_{jj}) \frac{P(z | H_j)}{P(z | H_0)}$$

siendo $J_0(z) = 1$ (referencia!)

Decidimos

$$z \rightarrow H_0 \text{ si } J_0 < J_1, J_0 < J_2, J_0 < J_3, \dots, J_0 < J_{M-1}$$

$$z \rightarrow H_1 \text{ si } J_1 < J_0, J_1 < J_3, \dots, J_1 < J_{M-1}$$

$$\vdots$$

$$z \rightarrow H_{M-1} \text{ si } J_{M-1} < J_0, J_{M-1} < J_1, \dots, J_{M-1} < J_{M-2}$$

Ejemplo: Detectar entre 3 señales en fondo de ruido

se decidirá con un vector de N muestras

$$\underline{z} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix}$$

$$\begin{aligned} S_0 &= DC \quad m_0 \\ S_1 &= DC \quad m_1 \\ S_2 &= DC \quad m_2 \end{aligned}$$

$$n \sim N(0, \sigma_n^2)$$

$$P(H_i) = \frac{1}{3}$$

$$C_{ii} = 0$$

Los costes

$$\begin{aligned} C_{ij} &= 0 \quad (\text{acertar}) \\ C_{ij} &= 1 \quad (\text{equivocarse}) \end{aligned}$$

Hay que calcular:

$$J_i(\underline{z}) = \sum_{\substack{j=0 \\ j \neq i}}^2 \frac{1}{3} \cdot \Lambda_j(\underline{z})$$

$$\begin{cases} J_0(\underline{z}) = \frac{1}{3} \Lambda_1(\underline{z}) + \frac{1}{3} \Lambda_2(\underline{z}) \\ J_1(\underline{z}) = \frac{1}{3} \underbrace{\Lambda_0(\underline{z})}_{1} + \frac{1}{3} \Lambda_2(\underline{z}) \\ J_2(\underline{z}) = \frac{1}{3} \underbrace{\Lambda_0(\underline{z})}_{1} + \frac{1}{3} \Lambda_1(\underline{z}) \end{cases}$$

Decidiremos H_0 cuando $J_0(\underline{z}) < J_1(\underline{z})$ y $J_0(\underline{z}) < J_2(\underline{z})$


- $\frac{1}{3} \Lambda_1(\underline{z}) + \frac{1}{3} \Lambda_2(\underline{z}) < \frac{1}{3} + \frac{1}{3} \Lambda_2(\underline{z}) \rightarrow \Lambda_1(\underline{z}) < 1$
- $\frac{1}{3} \Lambda_1(\underline{z}) + \frac{1}{3} \Lambda_2(\underline{z}) < \frac{1}{3} + \frac{1}{3} \Lambda_1(\underline{z}) \rightarrow \Lambda_2(\underline{z}) < 1$

$$Z_0 : \begin{cases} \Lambda_1(\underline{z}) < 1 \\ \Lambda_2(\underline{z}) < 1 \end{cases}$$

Procediendo igual

$$Z_1 : \begin{cases} \Lambda_1(\underline{z}) > 1 \\ \Lambda_2(\underline{z}) < \Lambda_1(\underline{z}) \end{cases}$$

$$Z_2 : \begin{cases} \Lambda_2(\underline{z}) > 1 \\ \Lambda_2(\underline{z}) > \Lambda_1(\underline{z}) \end{cases}$$



Habrá que expresar estas regiones como condición en \underline{z} (no como condición en $\Lambda(\underline{z})$)

$$\Lambda_1(\underline{z}) = \frac{p(\underline{z} | H_1)}{p(\underline{z} | H_0)} \quad \Lambda_2(\underline{z}) = \frac{p(\underline{z} | H_2)}{p(\underline{z} | H_0)}$$

$$\text{con } p(\underline{z} | H_i) = \prod_{j=1}^N p(z_j | H_i) = \prod_{j=1}^N \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left(-\frac{(z_j - m_i)^2}{2\sigma^2}\right)$$

Por tanto

$$p(\underline{z} | H_i) = \frac{1}{(2\pi\sigma^2)^{N/2}} \exp\left(-\sum_{j=1}^N \frac{(z_j - m_i)^2}{2\sigma^2}\right)$$

multiplicación
de exponentiales
en el sumatorio

$$\begin{aligned}\Lambda_1(\bar{z}) &= \frac{p(\underline{z} | H_1)}{p(\underline{z} | H_0)} = \exp\left[-\sum_{i=1}^N \frac{(z_i - m_1)^2}{2\sigma^2} + \sum_{i=1}^N \frac{(z_i - m_0)^2}{2\sigma^2}\right] \\ &= \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^N (z_i^2 - 2m_1 z_i + m_1^2 - z_i^2 + 2m_0 z_i - m_0^2)\right]\end{aligned}$$

entonces $\Lambda_1(\bar{z}) = 1$

$$\ln \Lambda_1(\bar{z}) = 0$$

$$-\frac{1}{2\sigma^2} \sum_{i=1}^N [2(m_0 - m_1)z_i + m_1^2 - m_0^2] = 0$$

$$2(m_0 - m_1) \sum z_i = (m_0^2 - m_1^2)N$$

$$\underbrace{\frac{1}{N} \sum_{i=1}^N z_i}_{\text{la media } \bar{z}} = \frac{m_0 + m_1}{2}$$

la media \bar{z}

igualmente

$$\Lambda_2(\bar{z}) = 1 \rightarrow \frac{1}{N} \sum_{i=1}^N z_i = \frac{m_0 + m_2}{2}$$

$$\Lambda_2(\bar{z}) = \Lambda_1(\bar{z}) \rightarrow \frac{1}{N} \sum_{i=1}^N z_i = \frac{m_1 + m_2}{2}$$

Por lo tanto podemos escribir las regiones como:


$$Z_0 \rightarrow \begin{cases} \Lambda_1(\bar{z}) < 1 \\ \Lambda_2(\bar{z}) < 1 \end{cases} \rightarrow \begin{cases} \bar{z} < \frac{m_0 + m_1}{2} \\ \bar{z} < \frac{m_0 + m_2}{2} \end{cases}$$

$$Z_1 \rightarrow \begin{cases} \Lambda_1(\bar{z}) > 1 \\ \Lambda_2(\bar{z}) < \Lambda_1(\bar{z}) \end{cases} \rightarrow \begin{cases} \bar{z} > \frac{m_0 + m_1}{2} \\ \bar{z} < \frac{m_1 + m_2}{2} \end{cases}$$

$$Z_2 \rightarrow \begin{cases} \Lambda_2(\bar{z}) > 1 \\ \Lambda_2(\bar{z}) > \Lambda_1(\bar{z}) \end{cases} \rightarrow \begin{cases} \bar{z} > \frac{m_0 + m_1}{2} \\ \bar{z} > \frac{m_1 + m_2}{2} \end{cases}$$

Ejemplo: $m_0 = 1$
 $m_1 = 2$
 $m_2 = 3$

$$\begin{aligned}H_0 &\rightarrow \frac{\bar{z}}{2} < \frac{3}{2} \rightarrow \bar{z} < \frac{3}{2} \\ H_1 &\rightarrow \frac{3}{2} < \frac{\bar{z}}{2} < \frac{5}{2} \rightarrow \frac{3}{2} < \bar{z} < \frac{5}{2} \\ H_2 &\rightarrow \frac{5}{2} < \frac{\bar{z}}{2} \rightarrow \bar{z} > \frac{5}{2}\end{aligned}$$



Anexo: Distribución chi-cuadrado (producto de gaussianas)

Supongamos

$$\ell = \underline{z}^T \cdot \underline{z} = \sum_{i=1}^N z_i^2 \rightarrow \text{Distribución chi-cuadrado con } N \text{ grados de libertad}$$

z_i gaussianas

$$p(\ell / H_0) = \begin{cases} \frac{\ell^{(N/2)-1}}{(2^{N/2})\sigma_i^N \Gamma(N/2)} \exp(-\frac{\ell}{2\sigma_i^2}) & \ell \geq 0 \\ 0 & \text{resto} \end{cases}$$

al calcular $\lambda_i(z)$
se va todo menos esto

Es muy útil cuando hay que detectar CAMBIOS en la varianza de la observación

$$m(m-\bar{m}) = \sqrt{N}(m-\bar{m})S$$

$$\frac{m(m-\bar{m})}{S} = \sqrt{N} \frac{m-\bar{m}}{S}$$

$\sqrt{N} \frac{m-\bar{m}}{S}$

$$\frac{m(m-\bar{m})}{S} = \sqrt{N} \sum_{i=1}^N \frac{t_i}{N} \leftarrow t_i = (z_i - \bar{z})/S$$

$$\frac{m(m-\bar{m})}{S} = \sqrt{N} \sum_{i=1}^N \frac{t_i}{N} \leftarrow (t_i)^2 = (z_i - \bar{z})^2/S^2$$

$$\left[\frac{m(m-\bar{m})}{S} > \frac{s}{\sqrt{N}} \right] \leftarrow \left[\lambda_2(s, N) \right] \leftarrow s$$

$$\left[\frac{m(m-\bar{m})}{S} < \frac{s}{\sqrt{N}} \right] \leftarrow \left[\lambda_1(s, N) \right] \leftarrow s$$

$$\left[\frac{m(m-\bar{m})}{S} < \frac{s}{\sqrt{N}} \right] \leftarrow \left[\lambda_1(s, N) \right] \leftarrow s$$

$$\left[\frac{m(m-\bar{m})}{S} > \frac{s}{\sqrt{N}} \right] \leftarrow \left[\lambda_2(s, N) \right] \leftarrow s$$

Problema 1. $H_0 \rightarrow$ transmitida continua DC de 0V
 $H_1 \rightarrow$ transmitida continua DC de 0'75V
 - Se suma ruido uniforme de varianza 0'5 y media nula
 - sólo una muestra en detección

- a) Deduza el detector óptimo y qué criterio está usando
 Obtenga el umbral adecuado

Dados los costes $C_{00} = C_{11} = 0$, $C_{01} = C_{10} = 1$ se deduce que el coste mínimo (criterio de Bayes) coincide con la mínima probabilidad de error (criterio MAP). Además, por ser las hipótesis equiprobables este es a su vez equivalente al criterio ML.

Por tanto: $\Lambda(z) \stackrel{H_1}{\geq} \stackrel{H_0}{\leq} \lambda = 1$



$$\frac{p(z|H_1)}{p(z|H_0)} \stackrel{H_1}{\geq} \stackrel{H_0}{\leq} 1$$

Se tiene:

$$H_0 : y = n$$

$$H_1 : y = 0'75 + n$$


Parece claro que el valor DC sólo desplazará las fdp de n , por lo tanto:



sabiendo que para una V.A. uniforme se tiene $\sigma_n^2 = \frac{(b-a)^2}{12} = \frac{(2b)^2}{12}$

podemos obtener b :

$$\sigma_n^2 = \frac{b^2}{3} = 0'5 \rightarrow b = \sqrt{1'5} = \sqrt{\frac{3}{2}}$$



Escogeremos H_0 si $y < 0'75 - b$

Escogeremos H_1 si $y > b$

¿Qué hacemos en la zona intermedia donde $\Lambda(z) = 1$?

Podemos tomar simplemente la mitad como umbral

$$y_{umb} = \frac{0'75 - b + b}{2} = 0'375$$

Por tanto: $D_0 \equiv y < 0'375$
 $D_1 \equiv y > 0'375$

$$P(H_0) = P(H_1) = 0'5$$

$$P_{FA} = \int_{D_1} p(y|H_0) dy = \int_{0'375}^b \frac{1}{2b} dy = 0'347$$

$$P_M = \int_{D_0} p(y|H_1) dy = \int_{-0'75-b}^{0'375} \frac{1}{2b} dy = 0'347$$

$$P_e = P(H_0) \cdot P_{FA} + P(H_1) \cdot P_M$$


$$= 0'347$$

Problema 2 :

1. Sólo una muestra en detección \rightarrow distribución Normal/Gaussiana

$$H_0: y = n \quad n = N(0, 1)$$

$$H_1: y = 1 + n \quad \text{media varianza}$$



a) Detector ML y umbral

Parece claro que: $p(y|H_0) = \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} = N(0, 1)$

$$p(y|H_1) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(y-1)^2}{2}} = N(1, 1)$$

$$\text{ML} \rightarrow \Lambda(y) = \frac{p(y|H_1)}{p(y|H_0)} \stackrel{H_1}{\geq} \lambda = 1$$

$$\Lambda(y) = \frac{e^{-\frac{(y-1)^2}{2}}}{e^{-\frac{y^2}{2}}} = e^{+\frac{y^2}{2} - \frac{(y-1)^2}{2}} = e^{\frac{-y^2 + y^2 + 2y - 1}{2}} = e^{+y - \frac{1}{2}}$$


por tanto: $e^{+y - \frac{1}{2}} \stackrel{H_1}{\geq} 1$

$\downarrow \ln$

$$y - \frac{1}{2} \stackrel{H_1}{\geq} 0$$

$$\frac{y + H_1}{H_0} = p \geq 1$$

$$\text{calcular } P(D_1|H_0) = \int_{-\infty}^{\infty} p(y|H_0) dy = Q(0.5) = 0.3085$$



b) Volver a calcular $P(D_1|H_0)$ pero integrando sobre la variable λ (una exponencial). Deberá obtener las fdp de λ condicionada a cada hipótesis.

$$\Lambda(y) = e^{y - \frac{1}{2}}$$

Sabemos que:

$$p(\lambda) = p(y) \cdot \frac{dy}{d\lambda} \quad i$$

$$\lambda \stackrel{H_1}{\geq} 1$$

por tanto

$$p(\lambda) = \frac{p(y)}{\lambda}$$

cálculo $dy/d\lambda$

$$\lambda = e^{y - \frac{1}{2}}$$

$$y = \ln \lambda + \frac{1}{2}$$

$$\frac{dy}{d\lambda} = \frac{1}{\lambda}$$

entonces:

$$p(\lambda|H_0) = \frac{p(y|H_0)}{\lambda} = \frac{1}{\lambda \sqrt{2\pi}} e^{-\frac{y^2}{2}} = \frac{1}{\lambda \sqrt{2\pi}} e^{-\frac{(\ln \lambda + \frac{1}{2})^2}{2}}$$

expresar "y" en función de λ

$$p(\lambda|H_1) = \frac{p(y|H_1)}{\lambda} = \dots = \frac{1}{\lambda \sqrt{2\pi}} e^{-\frac{(\ln \lambda - \frac{1}{2})^2}{2}}$$

$$P(D_1|H_0) = \int_{D_1}^{\infty} p(\lambda|H_0) d\lambda = \int_1^{\infty} \frac{1}{\lambda \sqrt{2\pi}} e^{-\frac{(\ln \lambda + \frac{1}{2})^2}{2}} d\lambda = Q(0.5) = Q(0.5)$$

cambio de variable

$$u = \ln \lambda + \frac{1}{2}$$

$$du = \frac{1}{\lambda} d\lambda$$

Problema 3. $H_0: f(y) = e^{-y} \cdot u(y)$ $u(y)$ es el escalón


$$H_1: f(y) = 2e^{-2y} u(y)$$

a) Detector y umbral, representar gráficamente

$$\Lambda(z) = \frac{p(y|H_1)}{p(y|H_0)} = \frac{2e^{-2y}}{e^{-y}} = 2e^{-y} \geq \lambda = \frac{(C_{10} - C_{00}) P(H_0)}{(C_{01} - C_{11}) P(H_1)} = 1$$

$$2e^{-y} \geq 1 \Rightarrow y \leq \ln 2$$

$$y \leq \frac{\ln 2}{\ln 2 - y}$$



b) P_{FA}

$$P_{D_1} = \Pr(D_1 | H_0) = \int_{D_1}^{\infty} p(y|H_0) dy = \int_{\ln 2}^{\infty} e^{-y} dy = -[e^{-y}]_{\ln 2}^{\infty} = \frac{1}{2}$$

$$P_{FA} = \Pr(D_0 | H_1) = \int_{D_0}^{\infty} p(y|H_1) dy = \int_0^{\ln 2} 2e^{-2y} dy = -[e^{-2y}]_0^{\ln 2} = 1 - \frac{1}{2} = \frac{1}{2}$$



Problema 4.


Sean x_1 y x_2 V.A. indep. uniformemente distribuidas $x_i \sim U(-\frac{2}{3}, \frac{2}{3})$

$$H_0 : y = x_1 + x_2$$


$$H_1 : y = 0'5 + x_1 + x_2$$

a) Detector óptimo y el umbral

$$p(x_1) = p(x_2)$$




$$p(y|H_0) = p(x_1) * p(x_2)$$



Calcularemos la convolución gráficamente

- Se empiezan a solapar en $-4/3$
- Aumenta linealmente hasta que coinciden las dos uniformes, y calculamos el valor del pico $\int_{-\infty}^{\infty} p(x_1) * p(x_2) dx$
- Disminuye linealmente el solape hasta ser nulo en $4/3$



$$p(y|H_1) = \text{desplazar } p(y|H_0) \text{ a } 0'5$$


$$= \delta(y-0'5) * p(y) * p(y)$$

Aplicando:

$$\lambda(z) = \frac{p(y|H_1)}{p(y|H_0)} \stackrel{H_1}{\geqslant} \lambda = \frac{(C_{10} - C_{00}) P(H_0)}{(C_{01} - C_{11}) P(H_1)} = 1$$

suma de 3 V.A.
la 1^a de ellas
es una constante
no aleatoria
(su $p(y)$ puede
verse una delta
en el valor
de la cte.)

$$ML \leftrightarrow p(y|H_1) \stackrel{H_1}{\geqslant} p(y|H_0) \stackrel{H_0}{=} (0'5) \cdot 1 = 0'5$$



Problema 5.

$$H_0 : f_x(x) = \frac{1}{2} e^{-|x|}$$

$$H_1 : f_x(x) = N(0, 4) = \frac{1}{\sqrt{2\pi} 4} e^{-\frac{x^2}{8}}$$

Determinar la LRT y el umbral

$$\Lambda(z) \stackrel{H_1}{\geq} \lambda$$

sin información de los costes ni de las $p(H_0)$, $p(H_1)$ asumir $\lambda = 1$

$$\Lambda(x) = \frac{p(x|H_1)}{p(x|H_0)} = \frac{\frac{1}{\sqrt{2\pi} 4} e^{-\frac{x^2}{8}}}{\frac{1}{2} e^{-|x|}} = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{8} + |x|} \stackrel{H_1}{\geq} 1$$

$$\ln \Lambda(x) = -\ln \sqrt{2\pi} - \frac{x^2}{8} + |x| \stackrel{H_1}{\geq} 0$$

$$\boxed{|x| - \frac{x^2}{8} \stackrel{H_1}{\geq} \ln \sqrt{2\pi}} = \frac{1}{2} \ln 2\pi$$


Para obtener los umbrales habrá que resolver la ecuación cuadrática

$$-|x|^2 + 8|x| - 4 \ln 2\pi \geq 0$$


$$[a = -1 \quad b = 8 \quad c = -4 \ln 2\pi] \quad x = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

$$\text{soluciones } x = \begin{cases} 1'06 \\ 6'94 \end{cases}$$


$$-(|x| - 1'06)(|x| - 6'94) \stackrel{H_1}{\geq} 0$$



Nota: Cuidado. Las regiones en x serán más!




Gráficamente tiene sentido:



Problema 6 : $H_0 : p(y) = a e^{-ay}$
 $H_1 : p(y) = b e^{-by}$ $a > b > 0$

en el problema original había que deducir esta constante $\Rightarrow \int_0^\infty k e^{-ay} dy = [-\frac{k}{a} e^{-ay}]_0^\infty = \frac{k}{a} = 1$

a) Criterio ML



b) Probabilidad de falsa alarma

$$P_{FA} = Pr(D_1, H_0) = \int_{D_1}^{\infty} p(y|H_0) dy = \int_{\frac{\ln(a/b)}{a-b}}^{\infty} e^{-ay} dy = [-e^{-ay}]_{\frac{\ln(a/b)}{a-b}}^{\infty} = e^{-\frac{a}{a-b} \ln(a/b)}$$

$$= e^{-\frac{a}{a-b} \ln(a/b)} = e^{\ln[(\frac{a}{b})^{\frac{a}{a-b}}]} = (\frac{b}{a})^{\frac{a}{a-b}}$$

Problema 7. $H_0 : y = x$ x : ruido gaussiano rectificado $\sim N(0, 1)$
 $H_1 : y = z$ $z \sim f_z(z) = e^{-z} u(z)$

$$\lambda(z) = \frac{p(y|H_1)}{p(y|H_0)} = \frac{e^{-z} u(z)}{\frac{2}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} u(z)} = \sqrt{\frac{\pi}{2}} e^{-z + \frac{z^2}{2}}$$

gaussiana rectificada

$$\frac{1}{2} \ln(\frac{\pi}{2}) - z + \frac{z^2}{2} \geq 0$$

$$(z - 1.74)(z - 0.26) \geq 0$$

Hay que resolver

$$z^2 - 2z + \ln(\frac{\pi}{2}) \geq 0$$

$$\begin{bmatrix} a=1 \\ b=-2 \\ c=\ln(\frac{\pi}{2}) \end{bmatrix} \rightarrow z = \{ 1.74, 0.26 \}$$

$$(z - 1.74)(z - 0.26) \geq 0$$

ecuación cuadrática

P_{FA} : zona sombreada (hacer integrales)

