



# Redes de Sensores

## Introducción & detección

Manuel A. Vázquez  
Joaquín Míguez  
Jose Miguel Leiva

30 de enero de 2024


# Índice

- 1 Introducción
  - Panorama
- 2 Estructuras/topologías
  - Tipos
- 3 Enrutamiento
  - Dijkstra
- 4 Detección
  - Tests locales
  - Test global
  - Ejemplo
  - Neyman-Pearson

# Índice


- 1 **Introducción**
  - Panorama
- 2 Estructuras/topologías
  - Tipos
- 3 Enrutamiento
  - Dijkstra
- 4 Detección
  - Tests locales
  - Test global
  - Ejemplo
  - Neyman-Pearson

# Redes de sensores




- WSN (wireless sensor network): conjunto de nodos sensores desplegados en una zona de interés para monitorizar un fenómeno físico.

# Redes de sensores




- WSN (wireless sensor network): conjunto de nodos sensores desplegados en una zona de interés para monitorizar un fenómeno físico.
- **Sensor/Nodo**: dispositivo con capacidad sensorial, procesado y almacenamiento local de datos, comunicaciones.

# Redes de sensores



- WSN (wireless sensor network): conjunto de nodos sensores desplegados en una zona de interés para monitorizar un fenómeno físico.
- **Sensor/Nodo**: dispositivo con capacidad sensorial, procesado y almacenamiento local de datos, comunicaciones.
- **Propiedades**: cooperación, adaptabilidad, auto-organización, robustez.

# Redes de sensores



- WSN (wireless sensor network): conjunto de nodos sensores desplegados en una zona de interés para monitorizar un fenómeno físico.
- **Sensor/Nodo**: dispositivo con capacidad sensorial, procesado y almacenamiento local de datos, comunicaciones.
- Propiedades: cooperación, adaptabilidad, auto-organización, robustez.
- **Centro de fusión**: dispositivo donde se integran los datos generados por los nodos sensores.

# Aplicaciones

- Militares: comando, control, comunicaciones, vigilancia, reconocimiento, [detección/tracking](#) de objetivos.



# Aplicaciones

- Militares: comando, control, comunicaciones, vigilancia, reconocimiento, [detección/tracking](#) de objetivos.
- Salud/medicina: monitorización, diagnóstico, asistencia, e.g.,
  - [CodeBlue](#) y Vital Dust, dispositivos que monitorizan ritmo cardíaco, oxígeno, electrocardiograma, y lo envía a una PDA.

# Aplicaciones

- Militares: comando, control, comunicaciones, vigilancia, reconocimiento, [detección/tracking](#) de objetivos.
- Salud/medicina: monitorización, diagnóstico, asistencia, e.g.,
  - [CodeBlue](#) y Vital Dust, dispositivos que monitorizan ritmo cardíaco, oxígeno, electrocardiograma, y lo envía a una PDA.
- Ingeniería civil, e.g.,
  - [Edificios inteligentes](#)
  - [Ciudades inteligentes](#)

# Aplicaciones

- Militares: comando, control, comunicaciones, vigilancia, reconocimiento, [detección/tracking](#) de objetivos.
- Salud/medicina: monitorización, diagnóstico, asistencia, e.g.,
  - [CodeBlue](#) y Vital Dust, dispositivos que monitorizan ritmo cardíaco, oxígeno, electrocardiograma, y lo envía a una PDA.
- Ingeniería civil, e.g.,
  - [Edificios inteligentes](#)
  - [Ciudades inteligentes](#)
- Monitorización ambiental, e.g.,
  - Princeton's [Zebrant Project](#)
  - [Red de sensores meteorológicos](#) desplegada en la Big Island de Hawaii.
  - Red de [sensores que monitorizan la ondas infrasónicas](#) en el volcán Tungurahua (Ecuador).


# Aplicaciones

- Militares: comando, control, comunicaciones, vigilancia, reconocimiento, [detección/tracking](#) de objetivos.
- Salud/medicina: monitorización, diagnóstico, asistencia, e.g.,
  - [CodeBlue](#) y Vital Dust, dispositivos que monitorizan ritmo cardíaco, oxígeno, electrocardiograma, y lo envía a una PDA.
- Ingeniería civil, e.g.,
  - [Edificios inteligentes](#)
  - [Ciudades inteligentes](#)
- Monitorización ambiental, e.g.,
  - Princeton's [Zebrant Project](#)
  - [Red de sensores meteorológicos](#) desplegada en la Big Island de Hawaii.
  - Red de [sensores que monitorizan la ondas infrasónicas](#) en el volcán Tungurahua (Ecuador).
- Agricultura, e.g.,
  - [Intel's Wireless Vineyard](#)

# Índice

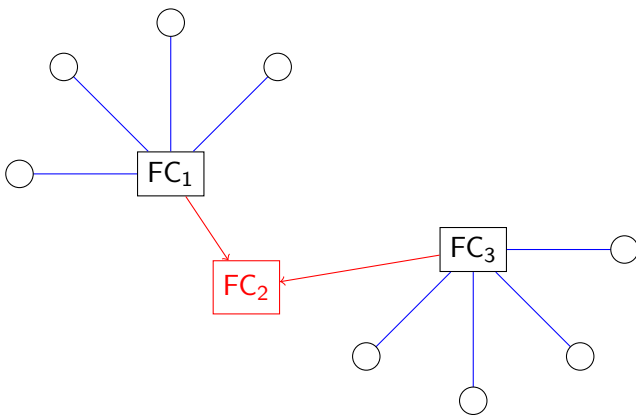
- 1 Introducción
  - Panorama
  
- 2 Estructuras/topologías
  - Tipos
  
- 3 Enrutamiento
  - Dijkstra
  
- 4 Detección
  - Tests locales
  - Test global
  - Ejemplo
  - Neyman-Pearson

# Estructura de estrella




- Comunicaciones: difusión (broadcast) y punto a multi-punto (multicast).
- Comandos de control desde el CF a los sensores. Datos desde los sensores al CF.

# Estructura jerárquica



Comunicaciones punto a punto entre CFs.

# Estructura en serie




- $S_i \equiv$  sensor  $i$ -ésimo,  $d_i \equiv$  dato/medición del sensor  $i$ -ésimo,  $L_i \equiv$  salida del procesador local del sensor  $i$ -ésimo,  $G \equiv$  salida global.
- Procesado recursivo:  $L_i = \phi(L_{i-1}, d_i)$ .



# Estructura en malla

## Comunicación *multipunto*



Comunicaciones punto-a-punto y técnicas de encaminamiento de datos.

# Índice


- 1 **Introducción**
  - Panorama
- 2 **Estructuras/topologías**
  - Tipos
- 3 **Enrutamiento**
  - Dijkstra
- 4 **Detección**
  - Tests locales
  - Test global
  - Ejemplo
  - Neyman-Pearson

# Búsqueda del camino óptimo

- En una red ad-hoc, es necesario establecer a priori la ruta a seguir para comunicar los nodos A y B.
- Al ser la energía limitada, se exige que los nodos A y B se comuniquen por la ruta menos costosa.
- En principio, complejidad del problema es combinatoria.
- Algoritmo de Dijkstra

# Algoritmo de Dijkstra

- Partimos de un grafo completamente conectado, donde cada conexión tiene un coste determinado.



- El coste de conectar  $A$  y  $B$  viene dado por la suma de los pesos de todas las conexiones en la ruta.

# Algoritmo de Dijkstra

- Tres tipos de nodos: el **nodo actual (NA)**, los nodos **visitados**, y los nodos **no visitados**.


# Algoritmo de Dijkstra

- Tres tipos de nodos: el **nodo actual (NA)**, los nodos **visitados**, y los nodos **no visitados**.
- Inicialización:
  - el nodo inicial,  $A$ , se marca como **nodo actual (NA)**, y su coste *acumulado* es  $0$
  - el resto de nodos se marcan como **no visitados**, y el coste del camino que llega a ellos es  $\infty$  (implícito, para no sobrecargar el dibujo)

# Algoritmo de Dijkstra

- Tres tipos de nodos: el **nodo actual (NA)**, los nodos **visitados**, y los nodos **no visitados**.
  - Inicialización:
    - el nodo inicial,  $A$ , se marca como **nodo actual (NA)**, y su coste *acumulado* es  $0$
    - el resto de nodos se marcan como **no visitados**, y el coste del camino que llega a ellos es  $\infty$  (implícito, para no sobrecargar el dibujo)
  - Repetir:
    - calculamos la distancia desde el **NA a todos sus vecinos no visitados** ; si para algún nodo la nueva distancia es menor que la anotada, ésta última se sobrescribe
    - marcamos el **nodo actual** como **visitado**
    - el nuevo **NA** es aquel que tiene el menor coste de entre los **no visitados**
- mientras  $B$  no haya sido marcado como **visitado**.


# Ejemplo



- Se desea encontrar el camino de menor peso entre  $A$  (sensor  $S_1$ ) y  $B$  (sensor  $S_7$ ).




# Ejemplo



## Inicialización


- Designamos el nodo inicial  $S_1$  como **nodo actual (NA)**.
- El coste del camino acumulado hasta el resto de nodos es  $\infty$ .

# Ejemplo




- Calculamos las distancias a los vecinos.

# Ejemplo




- Marcamos  $S_1$  como visitado.
- De los no visitados,  $S_4$  es el de menor peso: lo designamos NA.

# Ejemplo




- Calculamos distancias acumuladas a  $S_2$  ( $3 + 1 = 4$ ), a  $S_6$  ( $3 + 2 = 5$ ) y a  $S_7$  ( $3 + 8 = 11$ ).
- Como la nueva distancia acumulada a  $S_2$  es menor que la previamente calculada, la *sobreescibimos*. Es decir, el camino  $S_1 \rightarrow S_4 \rightarrow S_2$  tiene menor coste que  $S_1 \rightarrow S_2$ .

# Ejemplo




- Los nodos  $S_2$  y  $S_3$  son los de menor peso de los **no visitados**.
- Elegimos cualquiera de los dos como **NA**. En este caso,  $S_2$ .

# Ejemplo




- Calculamos distancia acumulada a  $S_5$ , que es el único vecino NV.

# Ejemplo



- Designamos  $S_3$  como **NA** y calculamos distancia acumulada a  $S_6$ . Como el resultado es superior al calculado previamente, lo ignoramos.


# Ejemplo



- Designamos a  $S_6$  como **NA**.
- Actualizamos la distancia a  $S_7$ , que es menor que la calculada previamente.




# Ejemplo



- Designamos a  $S_5$  como NA.
- Su distancia acumulada a  $S_7$  no mejora la anterior.

# Ejemplo



- En la siguiente iteración el nodo  $S_7$  sería marcado como **visitado**, aquí finalizaría el algoritmo.
- El coste más bajo que se ha encontrado corresponde a la ruta  $S_1 \rightarrow S_4 \rightarrow S_6 \rightarrow S_7$ .

# Índice

- 1 Introducción
  - Panorama
- 2 Estructuras/topologías
  - Tipos
- 3 Enrutamiento
  - Dijkstra
- 4 Detección
  - Tests locales
  - Test global
  - Ejemplo
  - Neyman-Pearson

# Red para detección centralizada

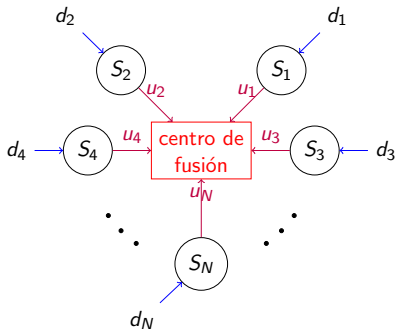


Diagrama básico de una red de sensores inalámbricos.

Estructura de una red con  $N$  sensores ( $i = 1, \dots, N$ )

- $S_i \equiv$  sensor  $i$ -ésimo
- $d_i \equiv$  observación en el sensor  $i$ -ésimo
- $u_i \in \{0, 1\} \equiv$  decisión en el sensor  $i$ -ésimo
- $u_0 \in \{0, 1\} \equiv$  decisión en el CF

# Procesamiento local

- El sensor  $S_i$ ,  $i \in \{1, \dots, N\}$ , registra la observación  $d_i$  y tiene que tomar una decisión binaria entre las hipótesis
  - $H_0$ : el fenómeno de interés no está presente
  - $H_1$ : el fenómeno de interés sí está presente
$$u_i = x \Leftrightarrow S_i \text{ "cree" que } H_x \text{ es la hipótesis correcta}$$
- $H_0$  es la “hipótesis nula”,  $H_1$  es la “hipótesis alternativa”

# Procesamiento local

- El sensor  $S_i$ ,  $i \in \{1, \dots, N\}$ , registra la observación  $d_i$  y tiene que tomar una decisión binaria entre las hipótesis
  - $H_0$ : el fenómeno de interés no está presente
  - $H_1$ : el fenómeno de interés sí está presente
$$u_i = x \Leftrightarrow S_i \text{ "cree" que } H_x \text{ es la hipótesis correcta}$$
- $H_0$  es la "hipótesis nula",  $H_1$  es la "hipótesis alternativa"
- A partir de  $d_i$  se calcula un estadístico  $t_i(d_i)$  que sirve para tomar la decisión. La observación  $d_i$  es aleatoria, mientras que  $t_i$  es una función determinista de  $d_i$ .

# Procesamiento local

- El sensor  $S_i$ ,  $i \in \{1, \dots, N\}$ , registra la observación  $d_i$  y tiene que tomar una decisión binaria entre las hipótesis
  - $H_0$ : el fenómeno de interés no está presente
  - $H_1$ : el fenómeno de interés sí está presente
$$u_i = x \Leftrightarrow S_i \text{ "cree" que } H_x \text{ es la hipótesis correcta}$$
- $H_0$  es la “hipótesis nula”,  $H_1$  es la “hipótesis alternativa”
- A partir de  $d_i$  se calcula un estadístico  $t_i(d_i)$  que sirve para tomar la decisión. La observación  $d_i$  es aleatoria, mientras que  $t_i$  es una función determinista de  $d_i$ .
- La salida del test binario es  $u_i \in \{0, 1\}$ :

$$u_i = \begin{cases} 0, & \text{si } t_i(d_i) < \beta_i \\ 1, & \text{si } t_i(d_i) > \beta_i \end{cases}$$

donde  $\beta_i$  es el umbral del test. Si  $t_i(d_i) \in \mathbb{R}$ , la probabilidad de que  $t_i(d_i) = \beta_i$  es 0.

## Procesamiento local: parámetros de interés

Los parámetros de interés del test  $i$ -ésimo (en el sensor correspondiente) son:

- la probabilidad de falsa alarma

$$\alpha_i = \mathbb{P}\{u_i = 1 | H_0\} = \mathbb{P}\{t_i(d_i) > \beta_i | H_0\},$$



## Procesamiento local: parámetros de interés

Los parámetros de interés del test  $i$ -ésimo (en el sensor correspondiente) son:

- la probabilidad de falsa alarma

$$\alpha_i = \mathbb{P}\{u_i = 1 | H_0\} = \mathbb{P}\{t_i(d_i) > \beta_i | H_0\},$$

- la probabilidad de detección

$$\gamma_i = \mathbb{P}\{u_i = 1 | H_1\} = \mathbb{P}\{t_i(d_i) > \beta_i | H_1\},$$

## Procesamiento local: parámetros de interés

Los parámetros de interés del test  $i$ -ésimo (en el sensor correspondiente) son:

- la probabilidad de falsa alarma

$$\alpha_i = \mathbb{P}\{u_i = 1|H_0\} = \mathbb{P}\{t_i(d_i) > \beta_i|H_0\},$$

- la probabilidad de detección

$$\gamma_i = \mathbb{P}\{u_i = 1|H_1\} = \mathbb{P}\{t_i(d_i) > \beta_i|H_1\},$$

- la probabilidad de pérdida

$$\varepsilon_i = \mathbb{P}\{u_i = 0|H_1\} = \mathbb{P}\{t_i(d_i) < \beta_i|H_1\}.$$

# Fusión de datos I

- Los sensores transmiten sus decisiones locales al centro de fusión (CF) de la red. En el CF, la “observación” es el vector

$$\mathbf{u} = \begin{bmatrix} u_1 \\ \vdots \\ u_N \end{bmatrix} \in \{0, 1\}^N.$$

# Fusión de datos I

- Los sensores transmiten sus decisiones locales al centro de fusión (CF) de la red. En el CF, la “observación” es el vector

$$\mathbf{u} = \begin{bmatrix} u_1 \\ \vdots \\ u_N \end{bmatrix} \in \{0, 1\}^N.$$

- El CF procesa el vector  $\mathbf{u}$  para obtener una salida global  $u_0 \in \{0, 1\}$ .

# Fusión de datos I

- Los sensores transmiten sus decisiones locales al centro de fusión (CF) de la red. En el CF, la “observación” es el vector

$$\mathbf{u} = \begin{bmatrix} u_1 \\ \vdots \\ u_N \end{bmatrix} \in \{0, 1\}^N.$$

- El CF procesa el vector  $\mathbf{u}$  para obtener una salida global  $u_0 \in \{0, 1\}$ .
- Sea  $\mathbb{P}\{H_k|\mathbf{u}\}$  la probabilidad de que la hipótesis  $H_k$  ( $k \in \{0, 1\}$ ) sea cierta dado el vector de decisiones locales  $\mathbf{u}$ . El test bayesiano óptimo es:

$$\mathbb{P}\{H_0|\mathbf{u}\} \underset{u_0=1}{\overset{u_0=0}{\geq}} \mathbb{P}\{H_1|\mathbf{u}\}$$

o equivalentemente

$$u_0 = \begin{cases} 0 & \text{si } \mathbb{P}\{H_0|\mathbf{u}\}/\mathbb{P}\{H_1|\mathbf{u}\} > 1 \\ 1 & \text{si } \mathbb{P}\{H_0|\mathbf{u}\}/\mathbb{P}\{H_1|\mathbf{u}\} < 1 \end{cases}$$

## Fusión de datos II

- Empleando el teorema de Bayes, podemos escribir la probabilidad a posteriori de la hipótesis  $H_k$  como

$$\mathbb{P}\{H_k|\mathbf{u}\} = \frac{\mathbb{P}\{\mathbf{u}|H_k\}\mathbb{P}\{H_k\}}{\mathbb{P}\{\mathbf{u}\}},$$

donde  $\mathbb{P}\{H_k\}$  es la probabilidad a priori de la hipótesis  $H_k$ .

- Si definimos el umbral  $\beta_0$  como el cociente de probabilidades a priori,

$$\beta_0 = \mathbb{P}\{H_0\}/\mathbb{P}\{H_1\},$$

y el estadístico  $T(\mathbf{u})$  como el cociente de verosimilitudes

$$T(\mathbf{u}) = \mathbb{P}\{\mathbf{u}|H_1\}/\mathbb{P}\{\mathbf{u}|H_0\}$$

entonces podemos reescribir el test bayesiano óptimo como

$$u_0 = \begin{cases} 1 & \text{si } T(\mathbf{u}) > \beta_0 \\ 0 & \text{si } T(\mathbf{u}) < \beta_0 \end{cases}$$

## Fusión de datos III

En resumen, para tomar la decisión *global* necesitamos

- un umbral *global*,  $\beta_0$ , que depende de:

- la probabilidad (*a priori*) de  $H_0$ ,  $\mathbb{P}\{H_0\}$
- la probabilidad (*a priori*)  $H_1$ ,  $\mathbb{P}\{H_1\}$

(son complementarias, i.e.,  $\mathbb{P}\{H_0\} + \mathbb{P}\{H_1\} = 1$ )

## Fusión de datos III

En resumen, para tomar la decisión *global* necesitamos

- un umbral *global*,  $\beta_0$ , que depende de:
  - la probabilidad (*a priori*) de  $H_0$ ,  $\mathbb{P}\{H_0\}$
  - la probabilidad (*a priori*)  $H_1$ ,  $\mathbb{P}\{H_1\}$(son complementarias, i.e.,  $\mathbb{P}\{H_0\} + \mathbb{P}\{H_1\} = 1$ )
- el estadístico  $T(\mathbf{u})$ , que depende de
  - la verosimilitud de  $H_0$ ,  $\mathbb{P}\{\mathbf{u}|H_0\}$
  - la verosimilitud de  $H_1$ ,  $\mathbb{P}\{\mathbf{u}|H_1\}$



## Fusión de datos III

En resumen, para tomar la decisión *global* necesitamos

- un umbral *global*,  $\beta_0$ , que depende de:
  - la probabilidad (*a priori*) de  $H_0$ ,  $\mathbb{P}\{H_0\}$
  - la probabilidad (*a priori*)  $H_1$ ,  $\mathbb{P}\{H_1\}$(son complementarias, i.e.,  $\mathbb{P}\{H_0\} + \mathbb{P}\{H_1\} = 1$ )
- el estadístico  $T(\mathbf{u})$ , que depende de
  - la verosimilitud de  $H_0$ ,  $\mathbb{P}\{\mathbf{u}|H_0\}$
  - la verosimilitud de  $H_1$ ,  $\mathbb{P}\{\mathbf{u}|H_1\}$

Si las decisiones locales son (condicionalmente) independientes entonces se puede escribir el estadístico  $T(\mathbf{u})$  en términos de los parámetros de los tests locales

$$T(\mathbf{u}) = \frac{\mathbb{P}\{\mathbf{u}|H_1\}}{\mathbb{P}\{\mathbf{u}|H_0\}} = \frac{\prod_{i=1}^N \mathbb{P}\{u_i|H_1\}}{\prod_{i=1}^N \mathbb{P}\{u_i|H_0\}}$$

# Fusión de datos: parámetros de interés


- Los parámetros del test son

$$\alpha_0 = \mathbb{P}\{u_0 = 1|H_0\} \equiv \text{probabilidad de falsa alarma}$$

$$\gamma_0 = \mathbb{P}\{u_0 = 1|H_1\} \equiv \text{probabilidad de detección}$$

$$\varepsilon_0 = \mathbb{P}\{u_0 = 0|H_1\} \equiv \text{probabilidad de pérdida}$$

# Ejemplo



- Al ser los sensores idénticos todos tienen la misma probabilidad de falsa alarma,  $\alpha_i = \alpha = 10^{-3}$ .
- Al estar a diferentes distancias del objetivo, tenemos  $\gamma_1 = 0,9$ ,  $\gamma_2 = 0,7$ ,  $\gamma_3 = 0,5$  y  $\gamma_4 = 0,3$ .
- Supongamos que  $\mathbb{P}\{H_1\} = 10^{-3}$ .

# Ejemplo 1

- El umbral viene dado por

$$\beta_0 = \mathbb{P}\{H_0\}/\mathbb{P}\{H_1\} = 0,999/0,001 \approx 10^3.$$

- Supongamos que  $\mathbf{u} = [1, 0, 0, 1]^T$ . Determinemos cuál es la decisión global  $u_0$ .

$$\begin{aligned} T(\mathbf{u}) &= \frac{\mathbb{P}\{\mathbf{u}|H_1\}}{\mathbb{P}\{\mathbf{u}|H_0\}} = \frac{\prod_{i=1}^4 \mathbb{P}\{u_i|H_1\}}{\prod_{i=1}^4 \mathbb{P}\{u_i|H_0\}} \\ &= \frac{\mathbb{P}\{u_1|H_1\}\mathbb{P}\{u_2|H_1\}\mathbb{P}\{u_3|H_1\}\mathbb{P}\{u_4|H_1\}}{\mathbb{P}\{u_1|H_0\}\mathbb{P}\{u_2|H_0\}\mathbb{P}\{u_3|H_0\}\mathbb{P}\{u_4|H_0\}} \\ &= \frac{\gamma_1}{\alpha_1} \frac{\epsilon_2}{(1 - \alpha_2)} \frac{\epsilon_3}{(1 - \alpha_3)} \frac{\gamma_4}{\alpha_4} \\ &= \frac{0,9}{10^{-3}} \frac{(1 - 0,7)}{0,999} \frac{(1 - 0,5)}{0,999} \frac{0,3}{10^{-3}} \\ &= 4,05 \times 10^4 > \beta_0 \Rightarrow u_0 = 1. \end{aligned}$$

## Ejemplo II

- Supongamos ahora que  $\mathbf{u} = [0, 1, 0, 0]^T$ . Determinemos cuál es la decisión global  $u_0$ .

$$\begin{aligned} T(\mathbf{u}) &= \frac{\epsilon_1}{(1 - \alpha_1)} \frac{\gamma_2}{\alpha_2} \frac{\epsilon_3}{(1 - \alpha_3)} \frac{\epsilon_4}{(1 - \alpha_4)} \\ &= \frac{0,1}{0,999} \frac{(0,7)}{10^{-3}} \frac{(1 - 0,5)}{0,999} \frac{(1 - 0,3)}{0,999} \\ &= 24,57 < \beta_0 \rightarrow u_0 = 0. \end{aligned}$$

# Lema de Neyman-Pearson

## Lema: Neyman-Pearson

Considere el problema de elegir entre dos hipótesis  $H_0$  y  $H_1$  a partir de un conjunto de datos  $D$ . El test que evalúa el cociente de verosimilitudes

$$T(D) = \frac{\mathbb{P}\{D|H_1\}}{\mathbb{P}\{D|H_0\}},$$

con probabilidad de falsa alarma constante  $\alpha$  (asociada a un umbral de decisión  $\beta$ ), maximiza la probabilidad de detección  $\gamma$ .

# Lema de Neyman-Pearson

## Lema: Neyman-Pearson

Considere el problema de elegir entre dos hipótesis  $H_0$  y  $H_1$  a partir de un conjunto de datos  $D$ . El test que evalúa el cociente de verosimilitudes

$$T(D) = \frac{\mathbb{P}\{D|H_1\}}{\mathbb{P}\{D|H_0\}},$$

con probabilidad de falsa alarma constante  $\alpha$  (asociada a un umbral de decisión  $\beta$ ), maximiza la probabilidad de detección  $\gamma$ .

- El test bayesiano óptimo pertenece a la clase de Neyman-Pearson y maximiza, por tanto, la probabilidad de detección  $\gamma$ .

# Lema de Neyman-Pearson

## Lema: Neyman-Pearson

Considere el problema de elegir entre dos hipótesis  $H_0$  y  $H_1$  a partir de un conjunto de datos  $D$ . El test que evalúa el cociente de verosimilitudes

$$T(D) = \frac{\mathbb{P}\{D|H_1\}}{\mathbb{P}\{D|H_0\}},$$

con probabilidad de falsa alarma constante  $\alpha$  (asociada a un umbral de decisión  $\beta$ ), maximiza la probabilidad de detección  $\gamma$ .

- El test bayesiano óptimo pertenece a la clase de Neyman-Pearson y maximiza, por tanto, la probabilidad de detección  $\gamma$ .
- Para una probabilidad de falsa alarma fija  $\alpha_i = \alpha \forall i$ , la probabilidad de detección global  $\gamma$  se maximiza si usamos tests locales óptimos en todos los sensores.