

Entrenador para el control de prótesis mioeléctricas



Proyecto Fin de Carrera

Autor: Víctor Rodríguez Doncel

Tutor: Ramón de la Rosa Steinz

⌘ Introducción

- Definición de la señal EMG
- Utilidad de la señal EMG

⌘ Estudio teórico

☒ Introducción

- Control proporcional - discreto
- Entrada y Salida
- Fases: entrenamiento y operación
- Reconocimiento de patrones

☒ Clasificadores

☒ Análisis Discriminante

- Entrenamiento
- QDF, Mahalanobis, LinealEuclídeo
- k-Vecinos

☒ Redes neuronales

☒ Extracción de características

- En el tiempo
- En la frecuencia
- En el tiempo - frecuencia

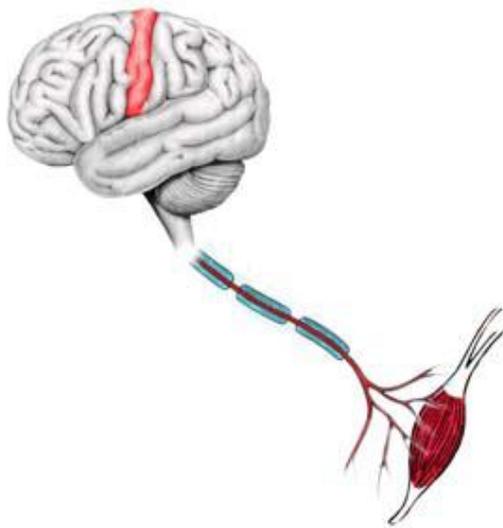
⌘ Aplicación práctica

- Trabajo previo y arquitectura
- Parámetros preferidos
- Aplicaciones

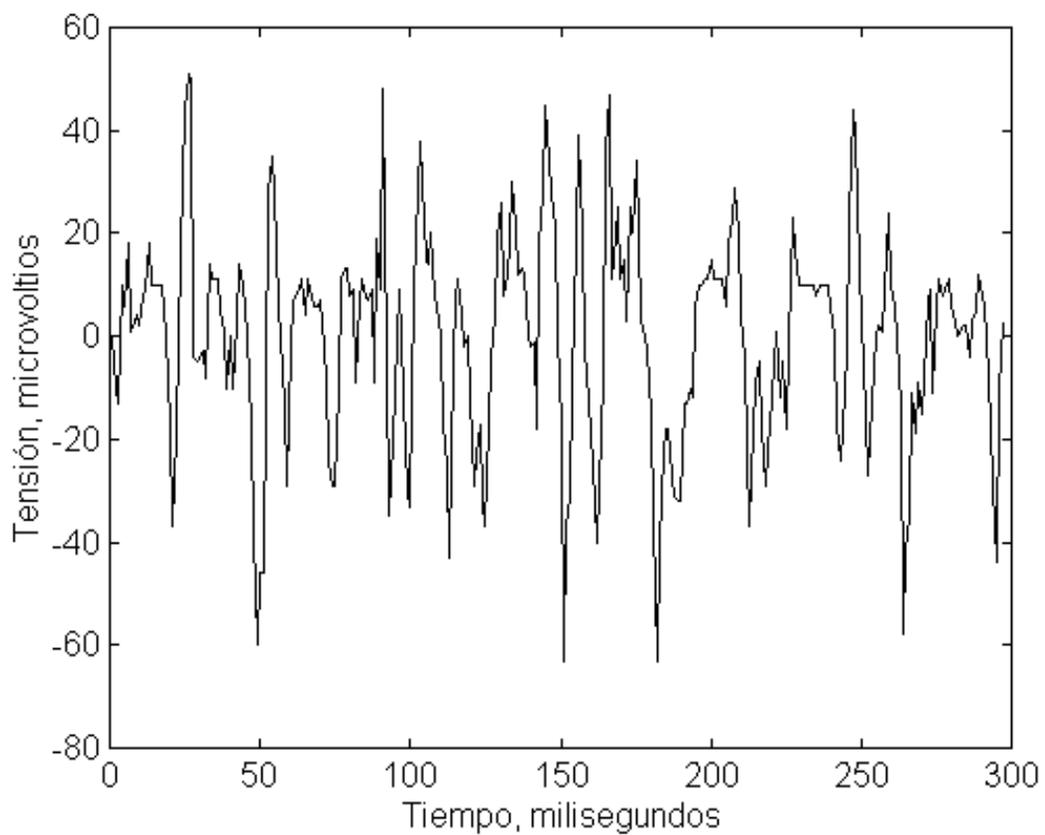
⌘ Conclusiones

Definición señal EMG

- ⌘ Señales bioeléctricas: EEG/EKG/EMG
- ⌘ EMG: Señal eléctrica de la contracción de los músculos.
- ⌘ Se puede medir con electrodos de superficie.

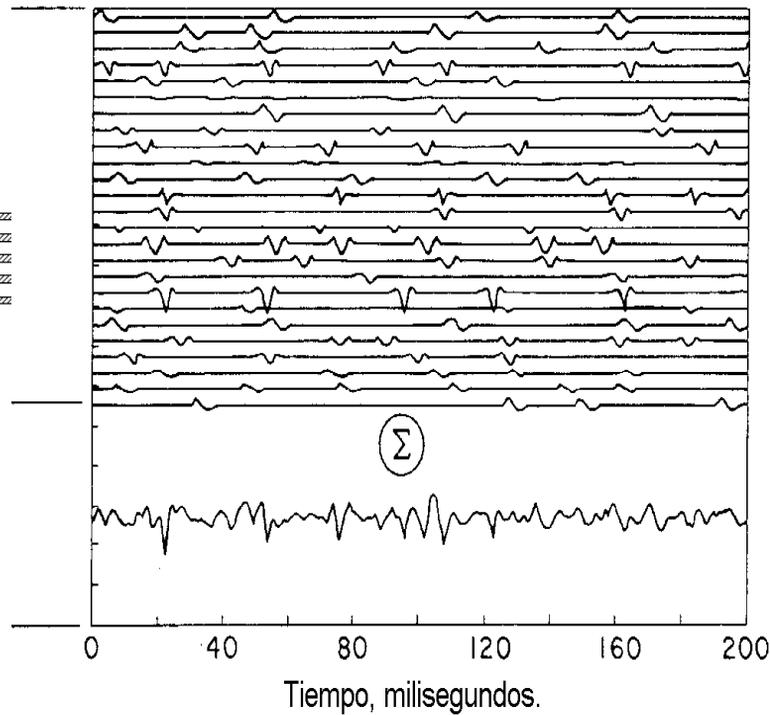
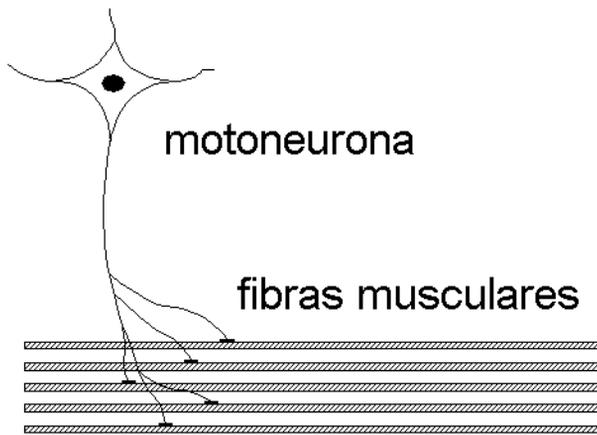


Ejemplo señal SEMG



Origen de la señal EMG

⌘ EMG: Suma de muchos procesos aleatorios.



Utilidad señal EMG

⌘ Medicina

⌘ Como origen de una señal de control

☑ Comercializadas: Prótesis mioeléctrica

☑ No comercializadas: tantas aplicaciones como se puedan imaginar



Control: proporcional / discreto



⌘ Control proporcional

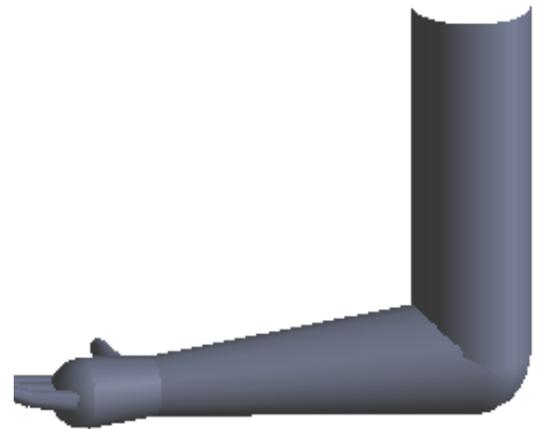
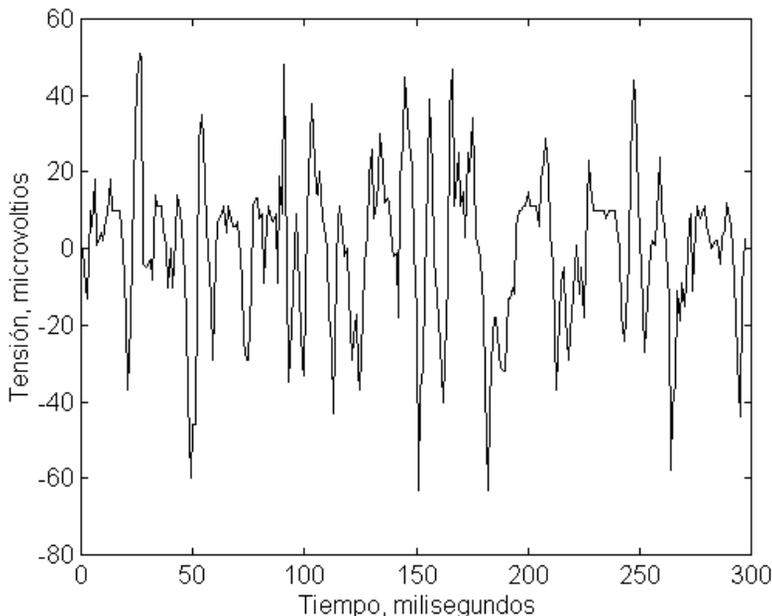
- ☑ Señal de salida es continua
- ☑ Problema de estimación
- ☑ Ejemplo: primeras prótesis

⌘ Control discreto

- ☑ Señal de salida es discreta
- ☑ Problema de detección
- ☑ Ejemplo: sistema aquí presentado
- ☑ Sistemas jerárquicos

Entrada y Salida

- ⌘ **Patrón:** Segmento a partir del cual se decide
- ⌘ **Estados:** Número de decisiones posibles
- ⌘ **Ejemplo nuestro:**
 - ⌘ Duración: 220 ms
 - ⌘ Canales: bíceps+tríceps.
- ⌘ **Ejemplo nuestro:**
 - ⌘ 5 - 7 Estados



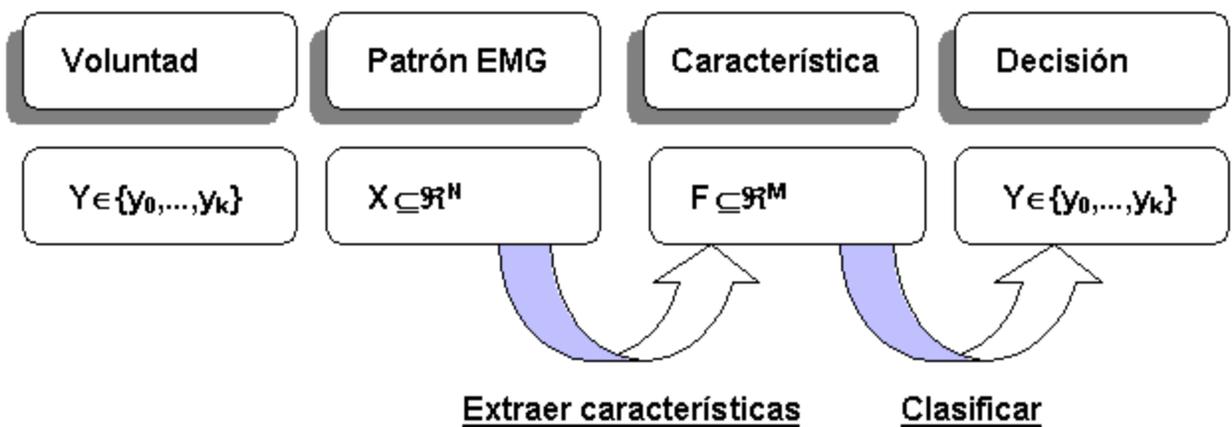
Fases:

Entrenamiento / Operación

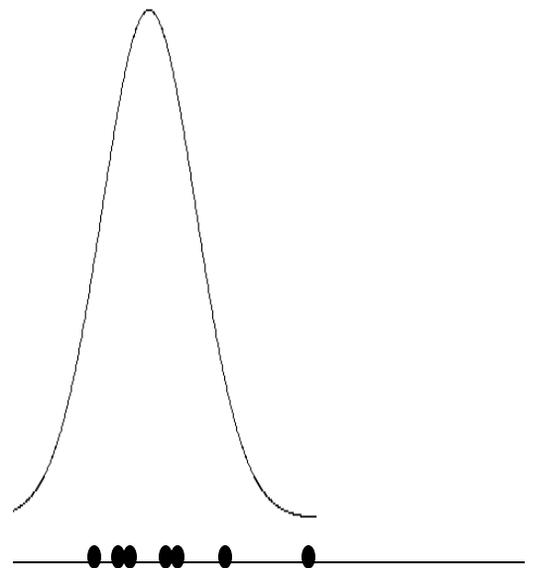
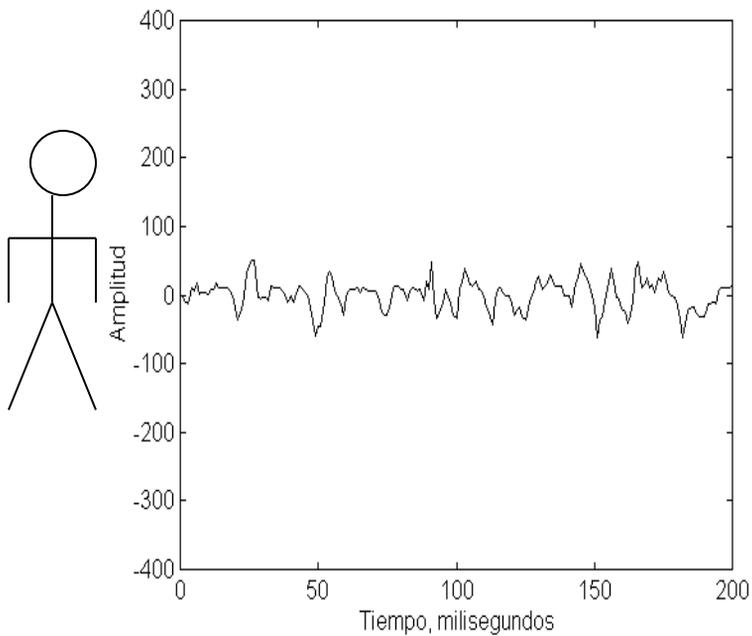
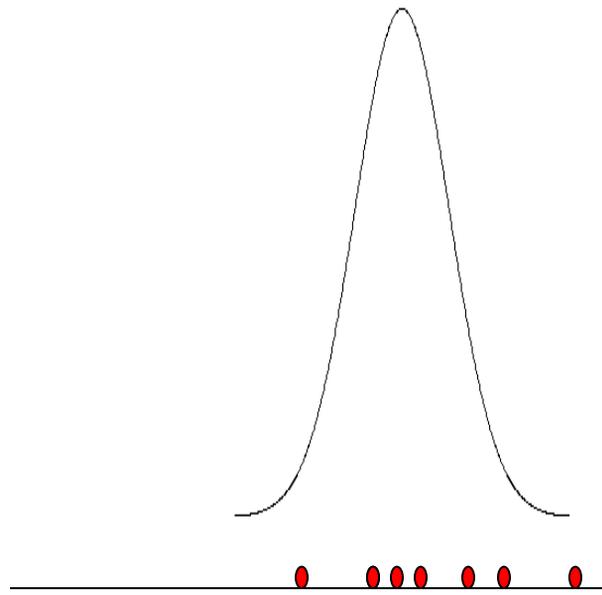
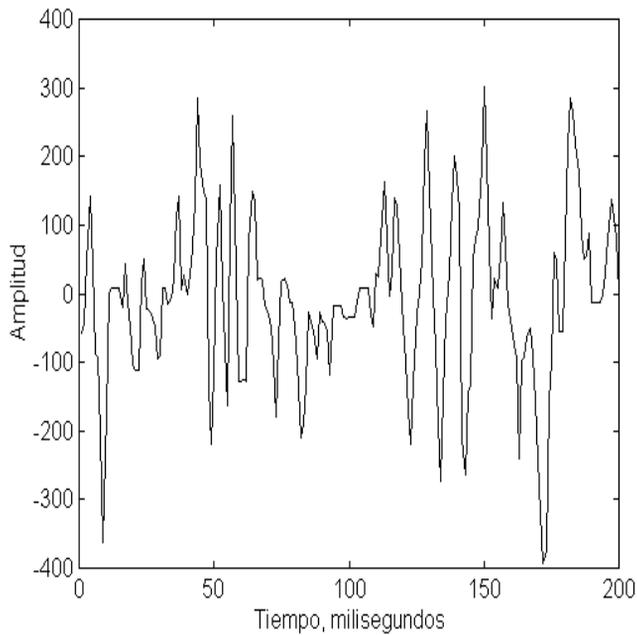


- ⌘ *Entrenamiento*: se conoce la entrada y se conoce la salida. El sistema debe aprender.
- ⌘ *Operación*: sólo se conoce la señal de entrada, y la salida se decide. El sistema debe clasificar sin errores.

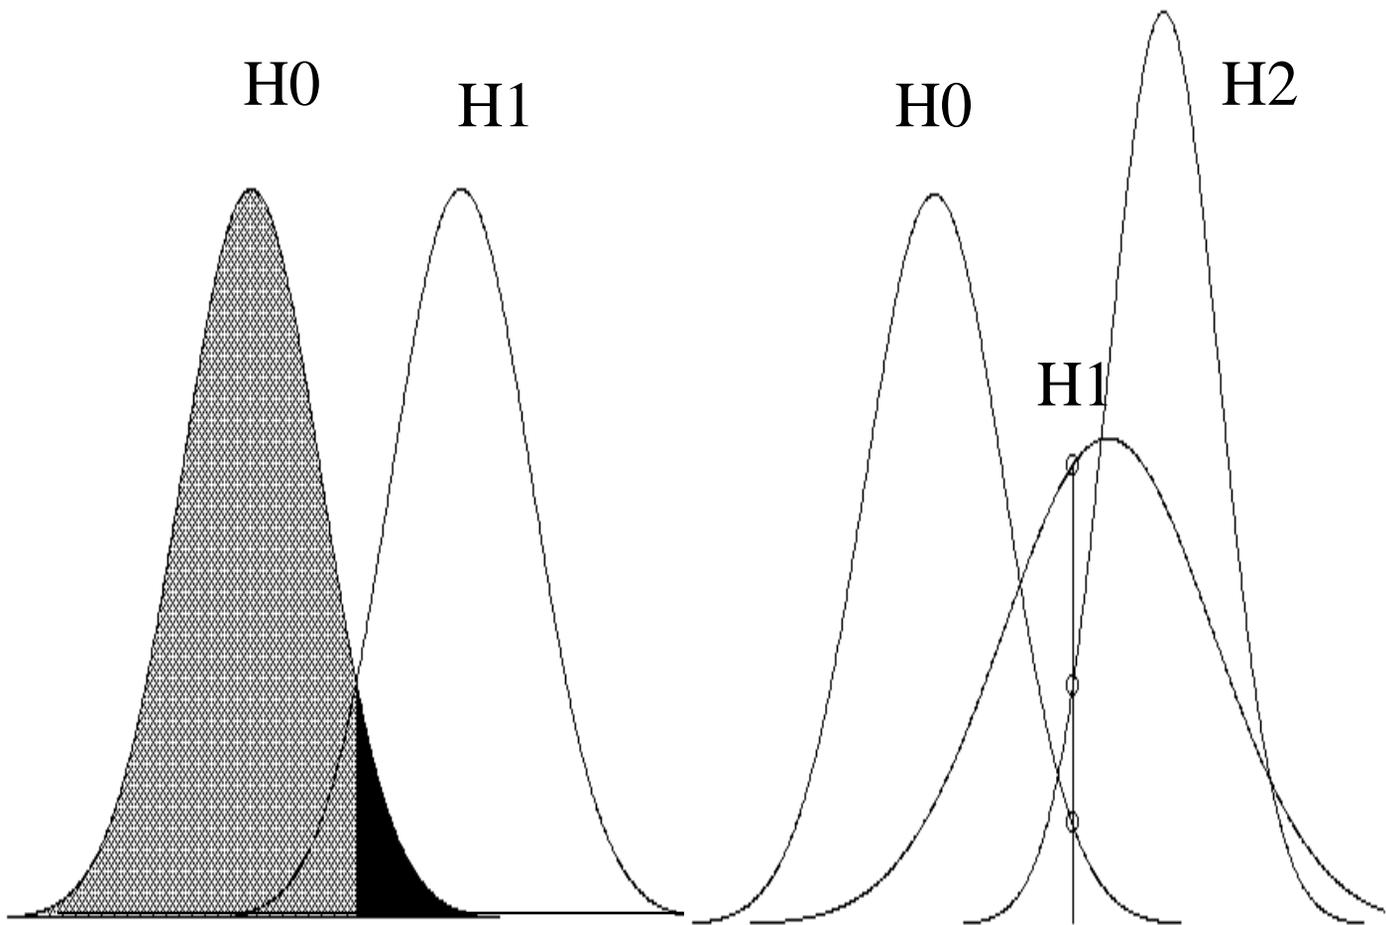
Reconocimiento de patrones



Entrenamiento con 1 carac.



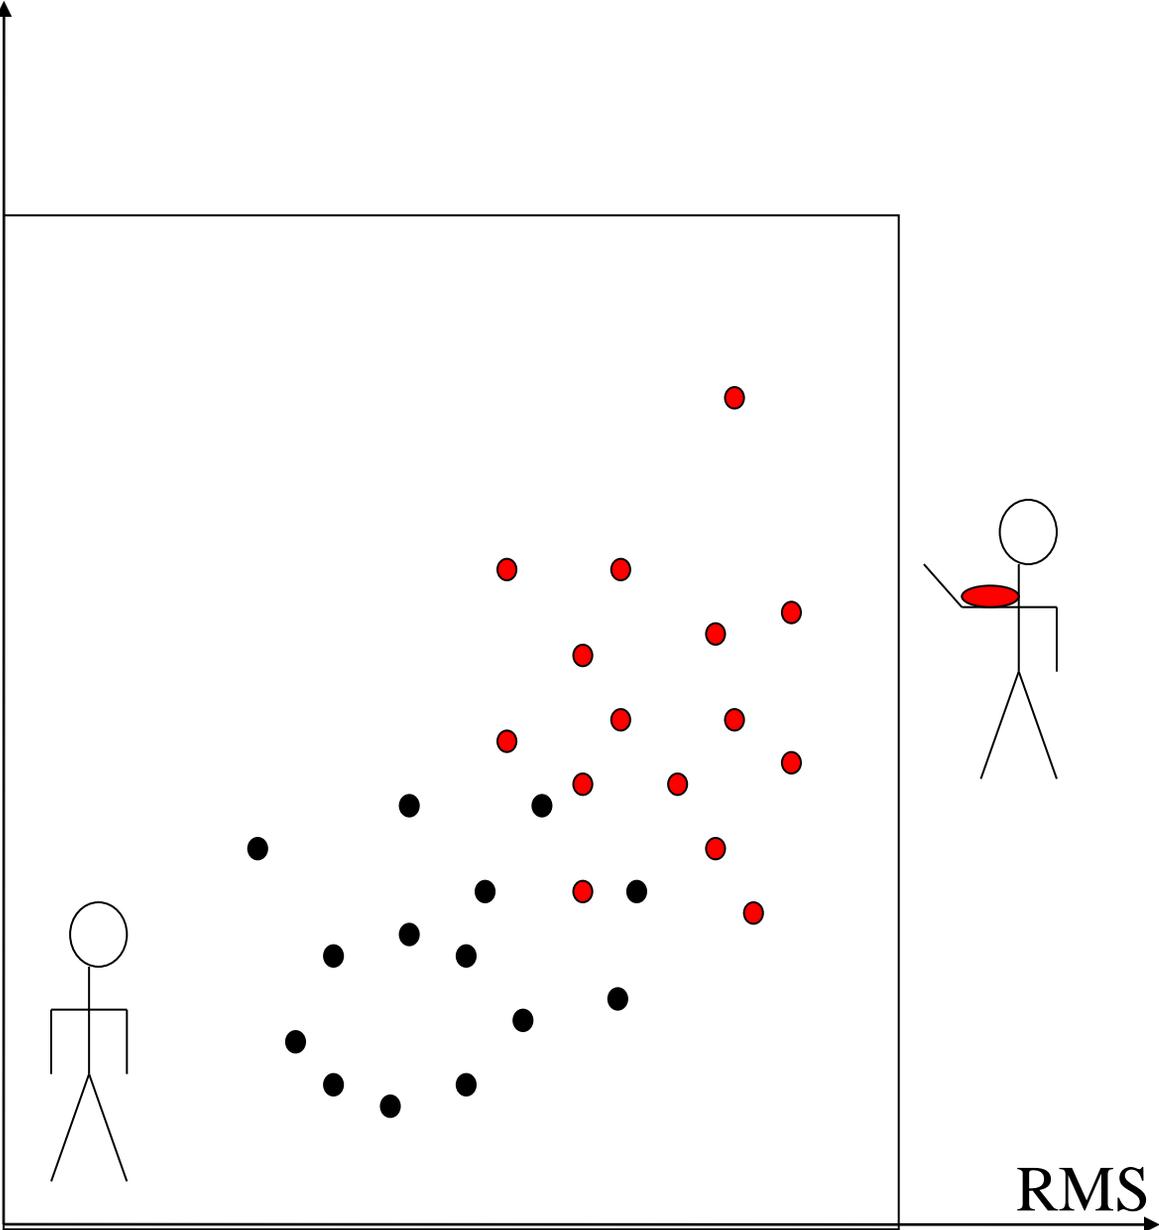
fdp gaussiana con 1 carac.



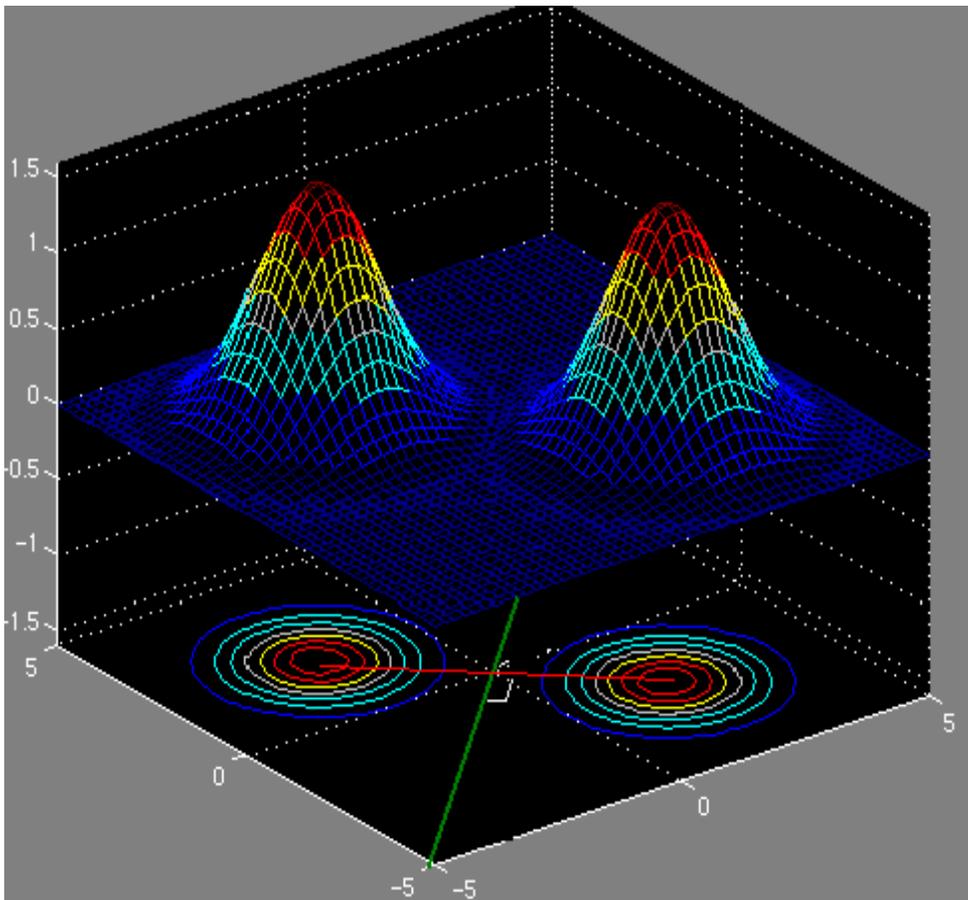
Entrenamiento con 2 carac.



ZC



fdp gaussiana con 2 car.



fdp gaussiana multivariada



$$p(x | H_k) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp\left(-\frac{(x - \bar{x})^2}{2\sigma_k^2}\right)$$

$$p(\mathbf{x} | H_k) = \frac{1}{C_k^{1/2} (2\pi)^{N/2}} \exp\left(-\frac{(\mathbf{x} - \bar{\mathbf{x}}_k)^T C_k^{-1} (\mathbf{x} - \bar{\mathbf{x}}_k)}{2}\right)$$

Entrenamiento: estimación de $\bar{\mathbf{x}}$ y de $\hat{\mathbf{C}}$

$$\hat{\bar{\mathbf{x}}}_k = \frac{1}{P} \sum_{p=1}^P \mathbf{x}_{kp}$$

$$\hat{\mathbf{C}}_k = \frac{\sum_{p=1}^P (\mathbf{x}_{kp} - \bar{\mathbf{x}}_k)(\mathbf{x}_{kp} - \bar{\mathbf{x}}_k)^T}{P}$$

Análisis discriminante

⌘ QDF

$$h_k(\mathbf{x}) = \ln(|C_k|) + (\mathbf{x} - \bar{\mathbf{x}}_k)^T C_k^{-1} (\mathbf{x} - \bar{\mathbf{x}}_k)$$

⌘ Mahalanobis

$$h_k(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}}_k)^T C_k^{-1} (\mathbf{x} - \bar{\mathbf{x}}_k)$$

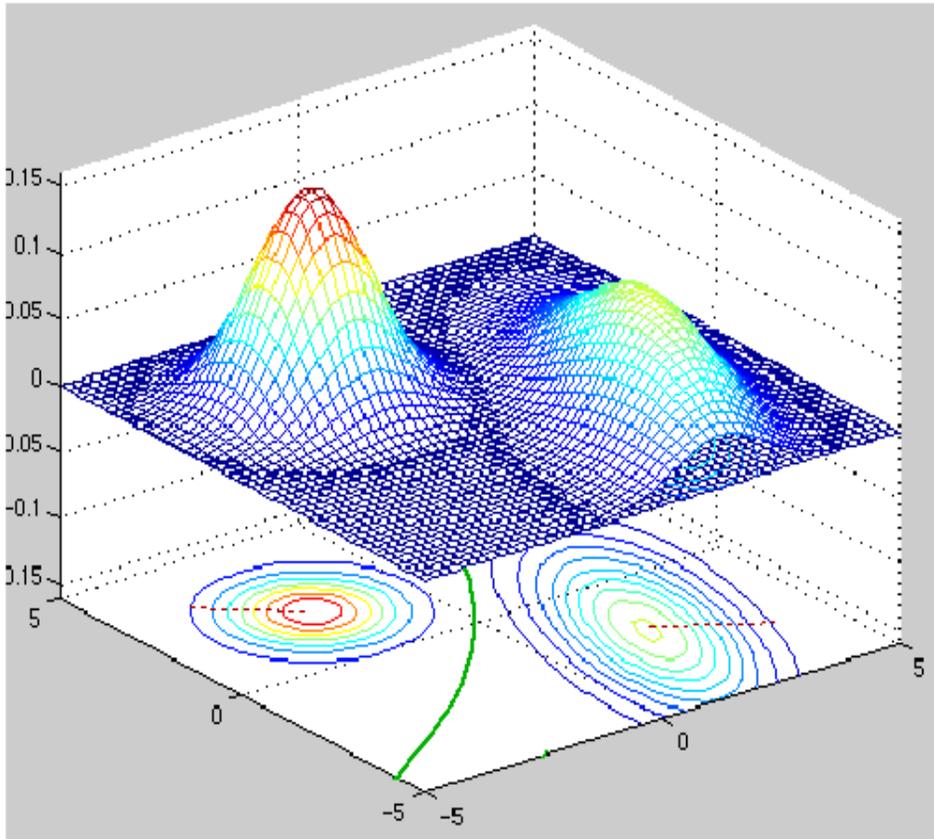
⌘ LDF

$$h_k(\mathbf{x}) = \bar{\mathbf{x}}_k^T C^{-1} \bar{\mathbf{x}}_k - 2\mathbf{x}^T C^{-1} \bar{\mathbf{x}}_k$$

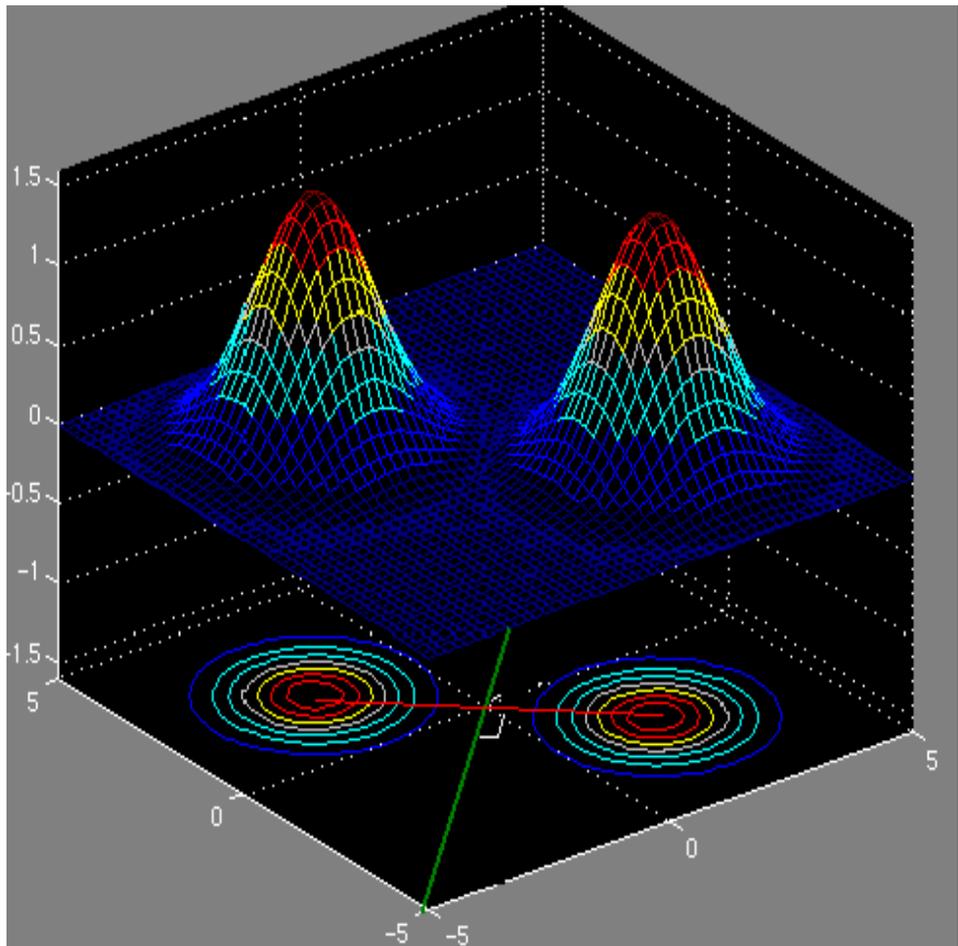
⌘ Euclídeo

$$h_k(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}}_k)^T (\mathbf{x} - \bar{\mathbf{x}}_k)$$

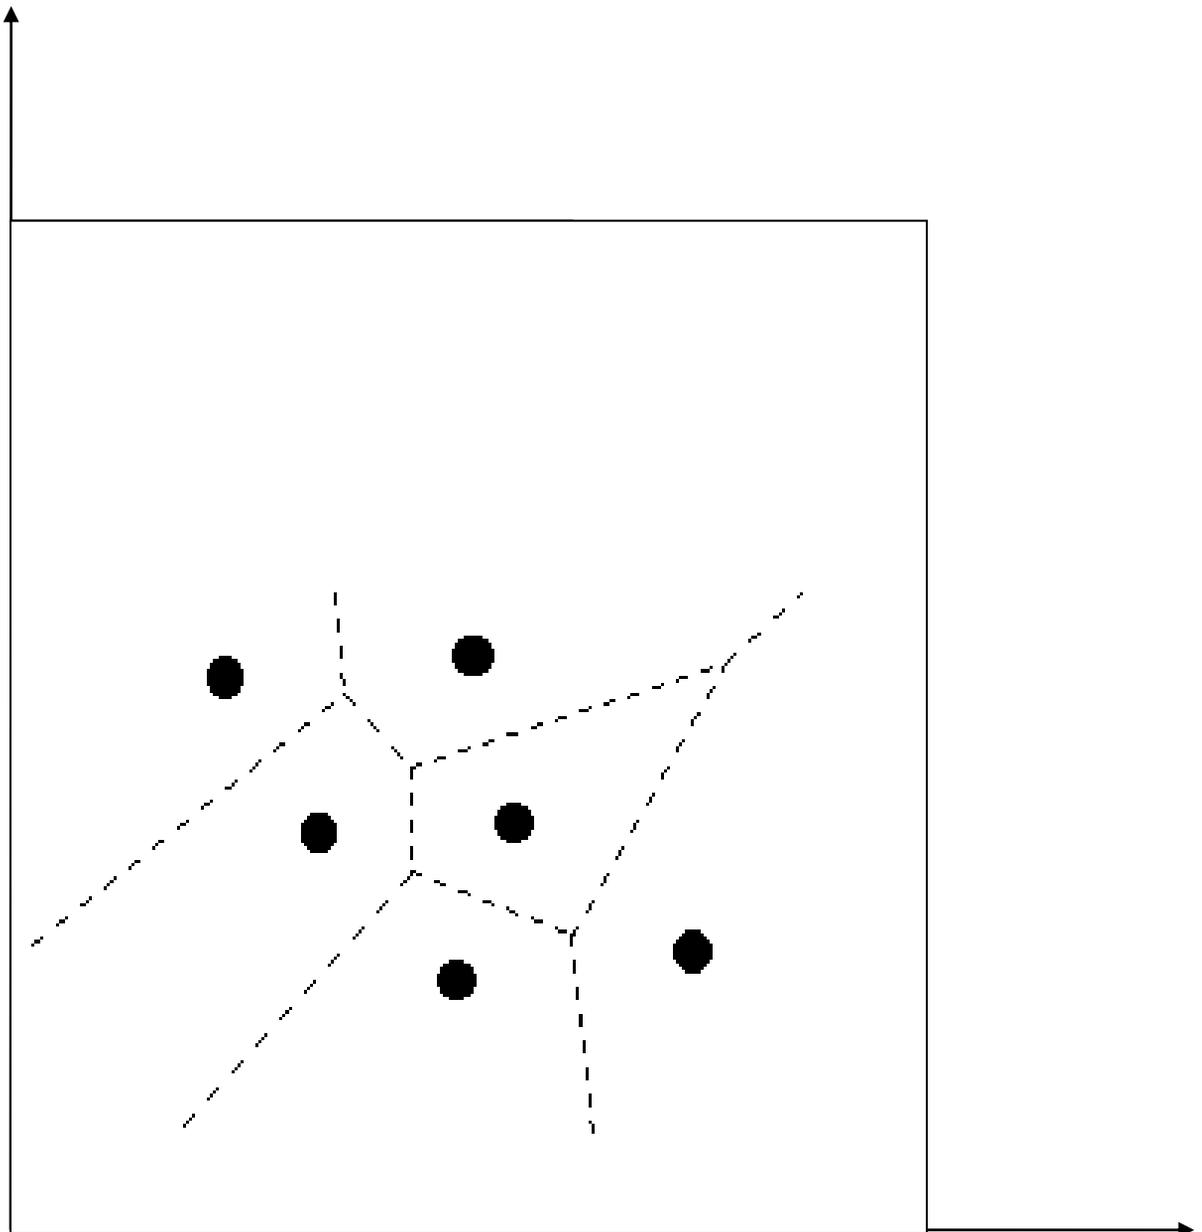
Análisis QDF o Mahalanobis



Análisis discriminante lineal



Clasificador de distancia

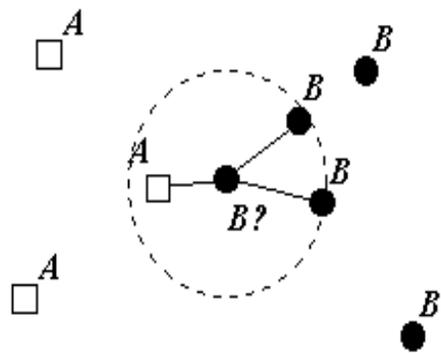
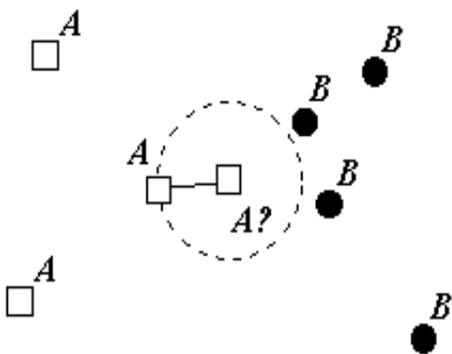


Clasificador k-vecinos

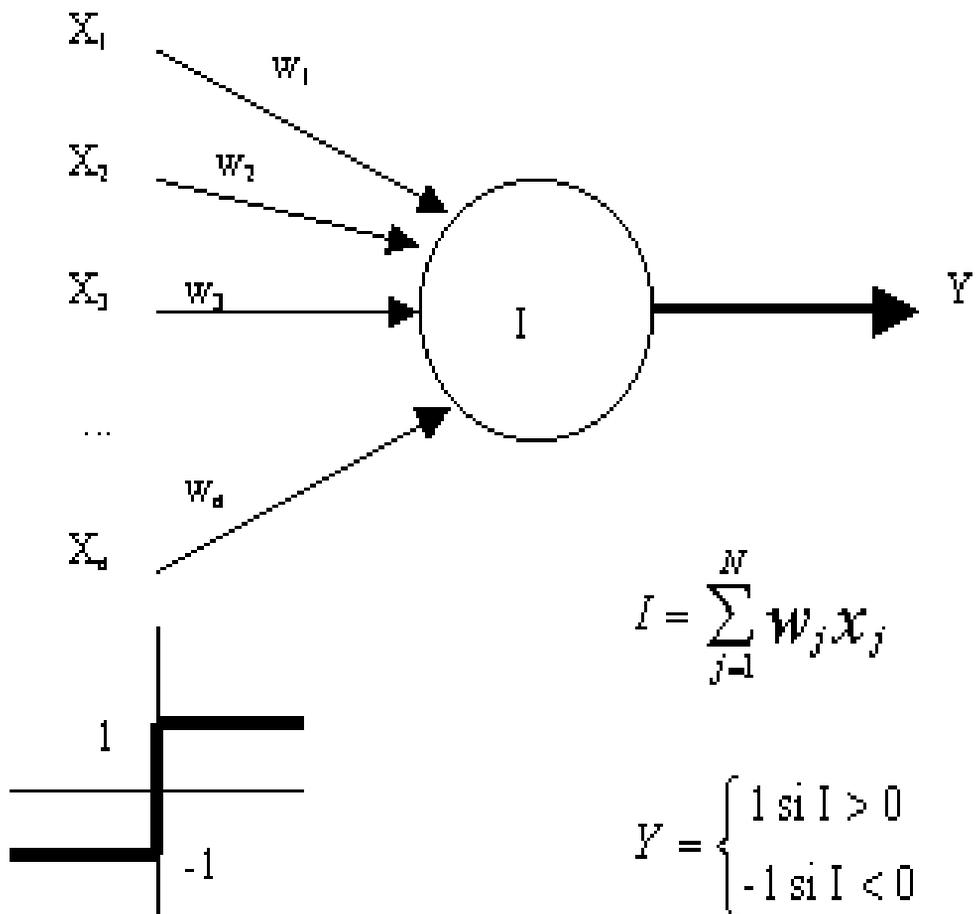
⌘ Varios representantes por cada clase.

⌘ Elección del vecino más próximo

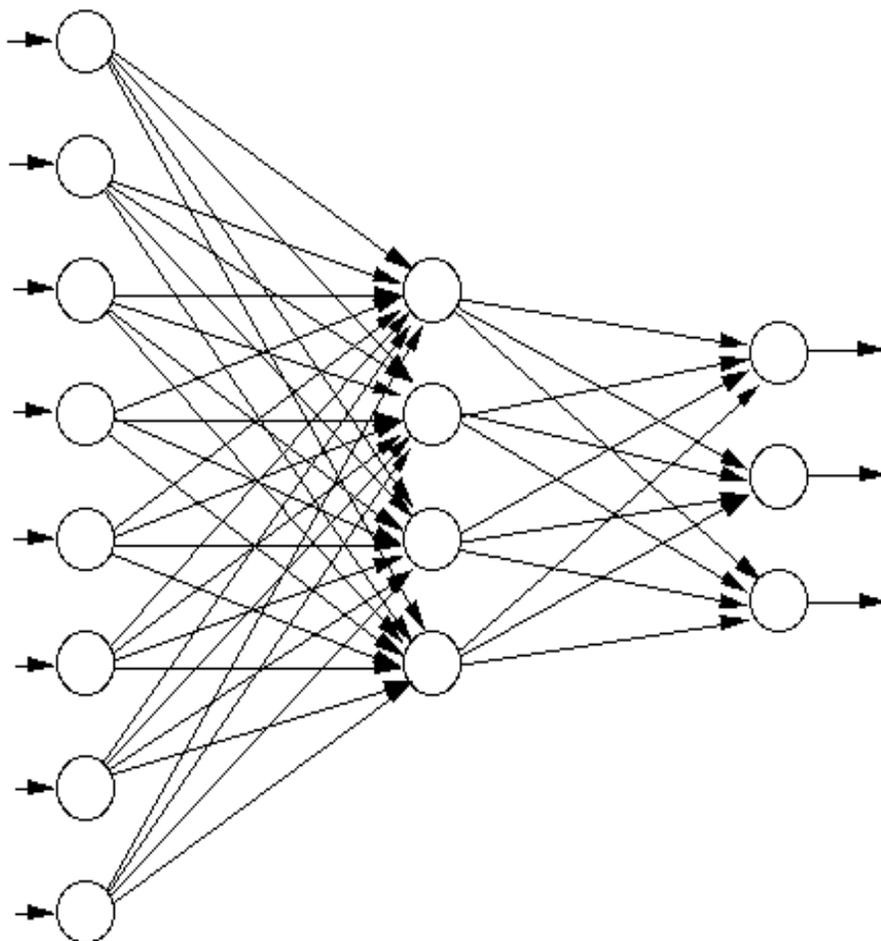
⌘ Elección del vecino más representado



Red neuronal: perceptrón



Red neuronal de tres capas



Extracción de características temporales

⌘ Valor absoluto medio:

$$MAV = \frac{1}{N} \sum_{n=1}^N |x(n)|$$

⌘ Momentos orden k: $VAR = \frac{1}{N} \sum_{n=1}^N x^2(n)$

⌘ Longitud de la señal:

$$WL = \frac{1}{N} \sum_{n=2}^N (x(n) - x(n-1))$$

⌘ Histograma de amplitudes

Extracción de características frecuenciales (I)

⌘ Cruces con cero:

$$ZC = \frac{1}{N} \sum_{n=2}^N \text{sgn}(-x(n)x(n-1))$$

⌘ Momentos
frecuenciales:

$$M_k = \frac{\int_0^{f_{max}} f^k P(f) df}{\int_0^{f_{max}} P(f) df}$$

⌘ DFT es inadecuada

Extracción de características frecuenciales (II)

⌘ Modelo AR:

- 1. Entrenamiento es calcular parámetros:

$$x_k(n) = \sum_{i=2}^s \hat{a}_i x_k(n-i) + \hat{e}_n$$

- 2. Operación es asignar al que minimiza el error

$$E_k(n) = \frac{1}{N-p} \sum_{j=n-N+p+1}^n (\hat{x}(n) - x_k(n))^2$$

Extracción de características frecuenciales (III)

- El espectro puede hallarse en el plano Z a partir de los parámetros del modelo AR

$$H(z) = \left[1 + \sum_{i=0}^s a_i z^{-i} \right]$$

- Coeficientes cepstrales:

$$C(z) = \ln[H(z)] = \sum_{i=0}^s c_i z^{-i}$$

Extracción de características de frecuencia - tiempo



⌘ Transformada STFT

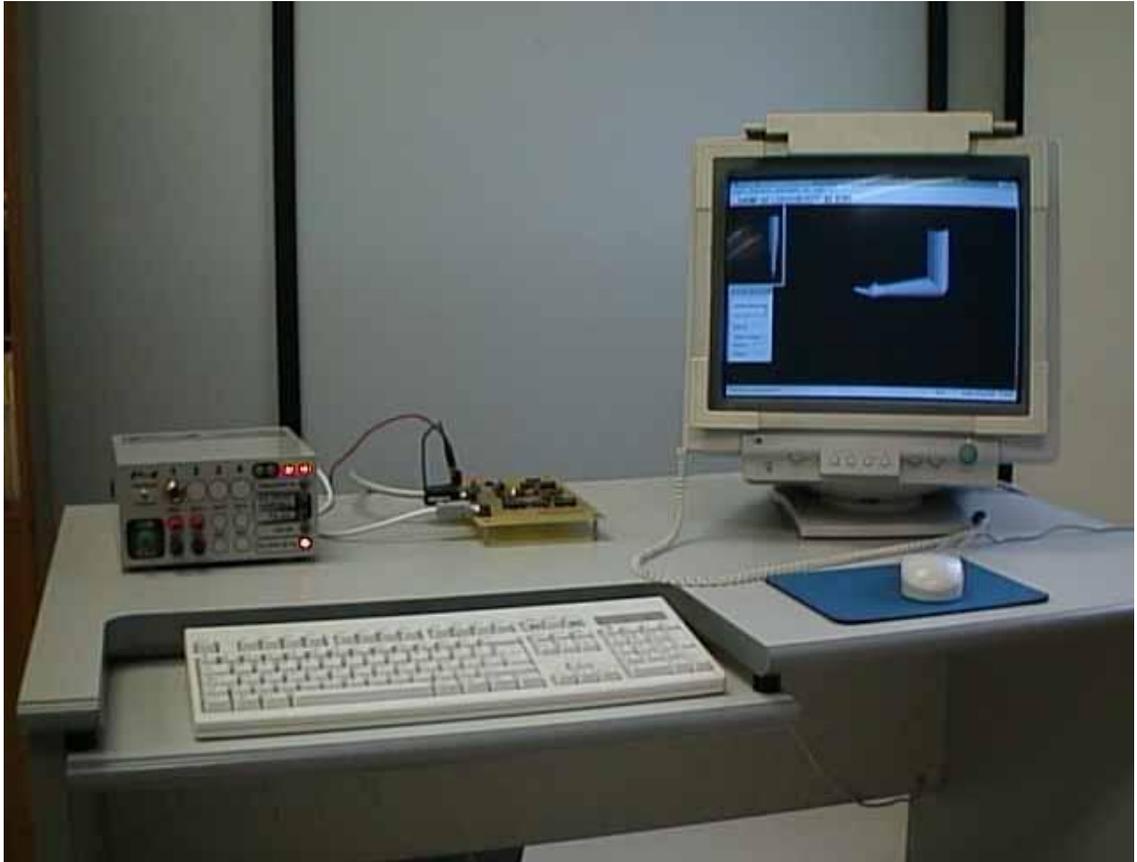
⌘ Transformada wavelet

☑ wavelet continua

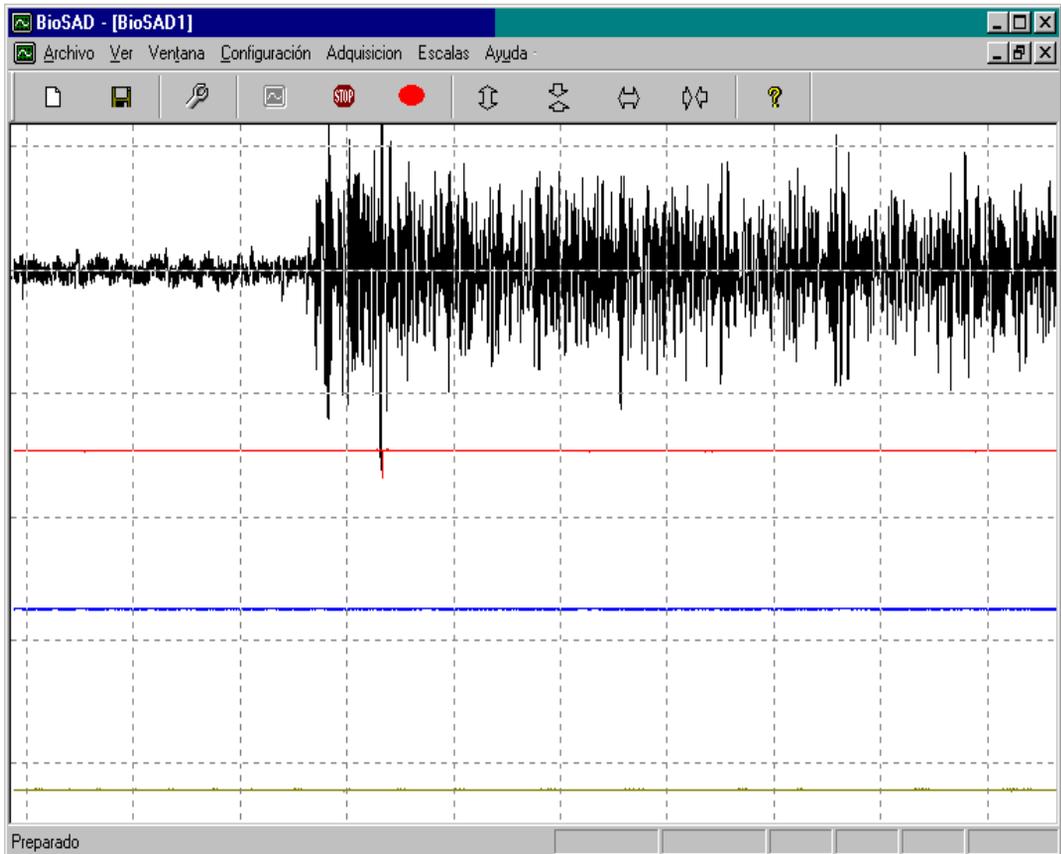
☑ wavelet discreta

☑ wavelet packets

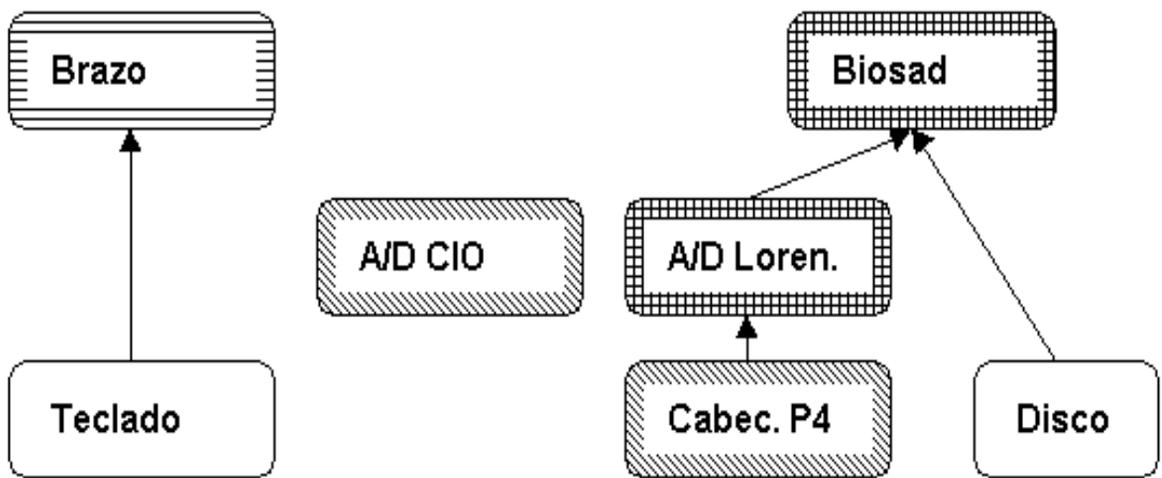
Trabajo previo (I)



Trabajo previo (II)

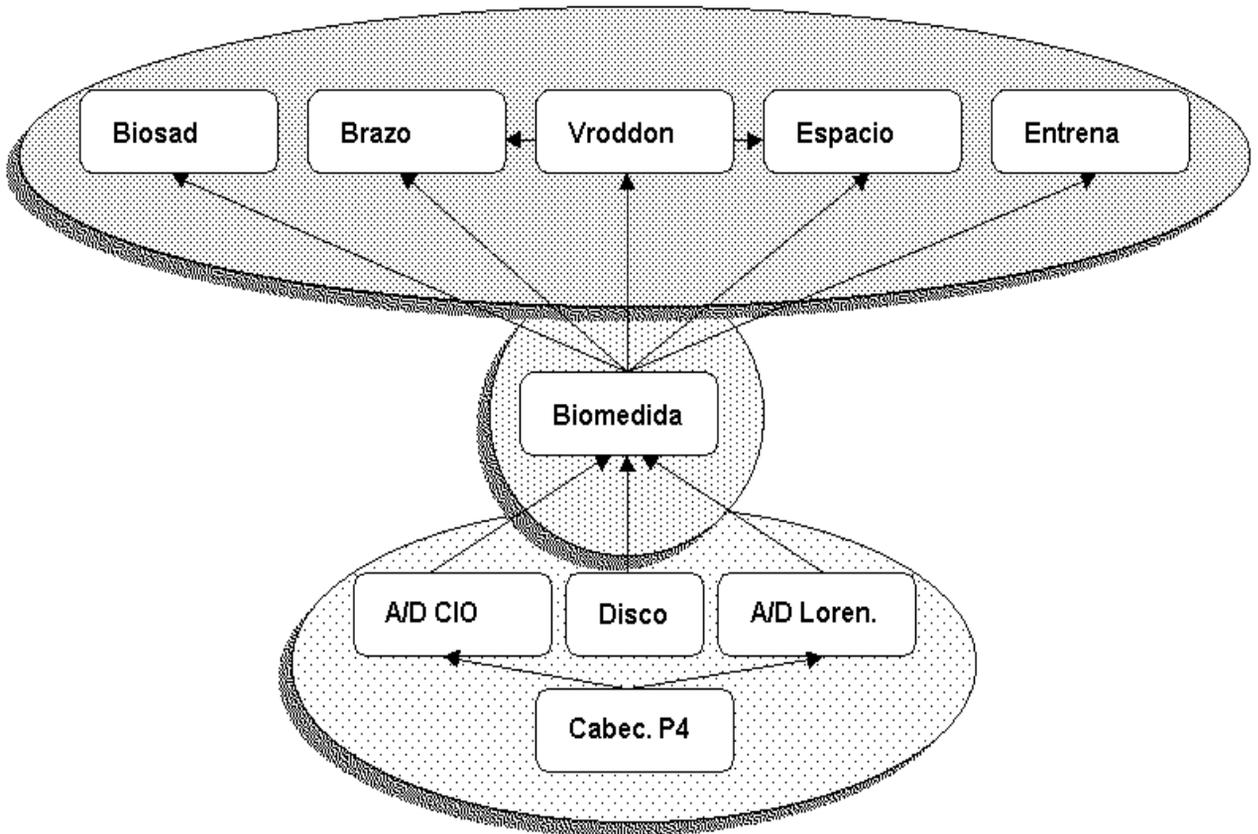


Trabajo previo (III)

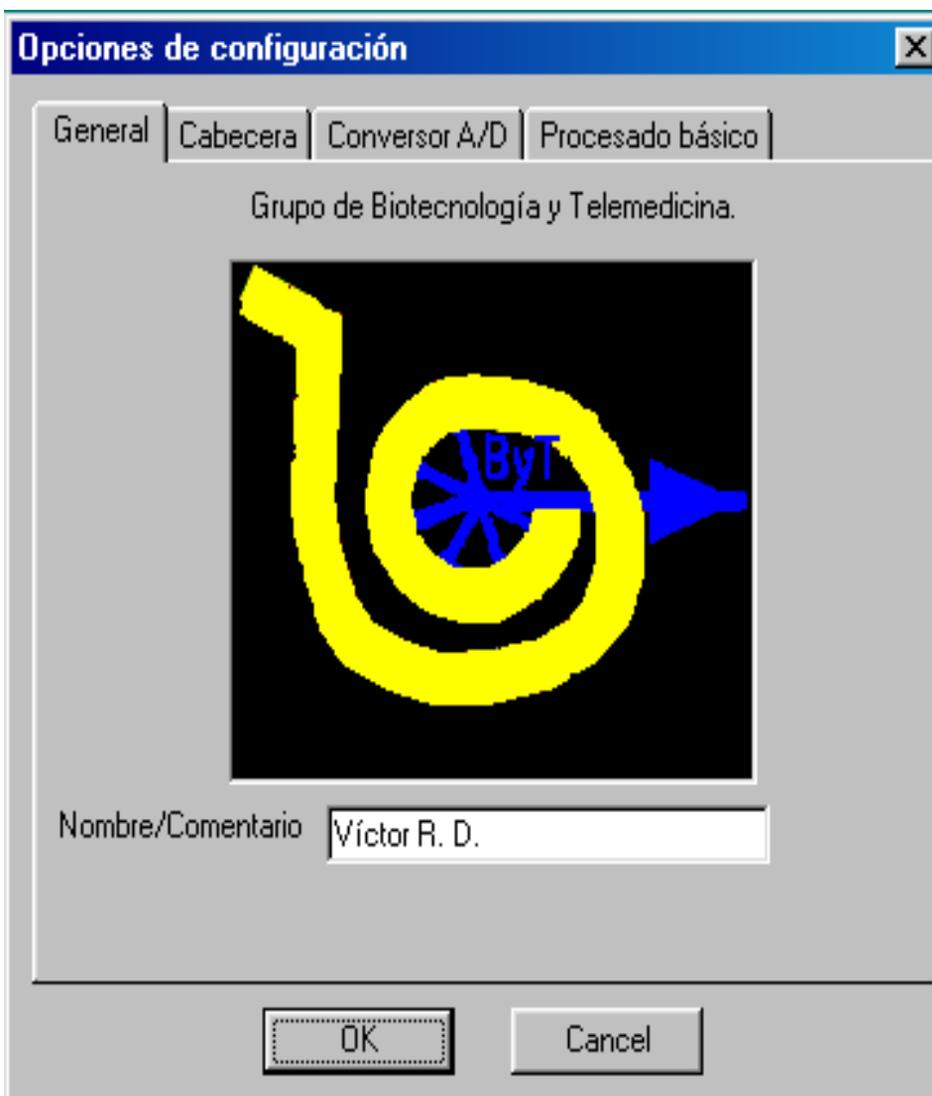


 R. de la Rosa  Lorenzo F.  A. Hernández

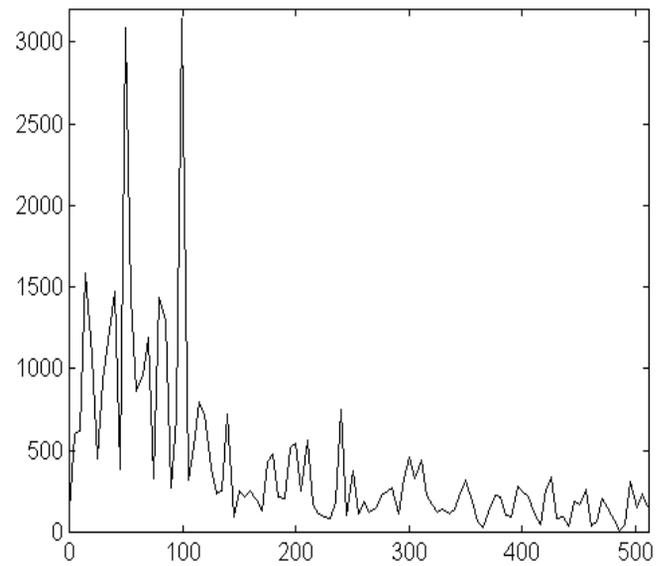
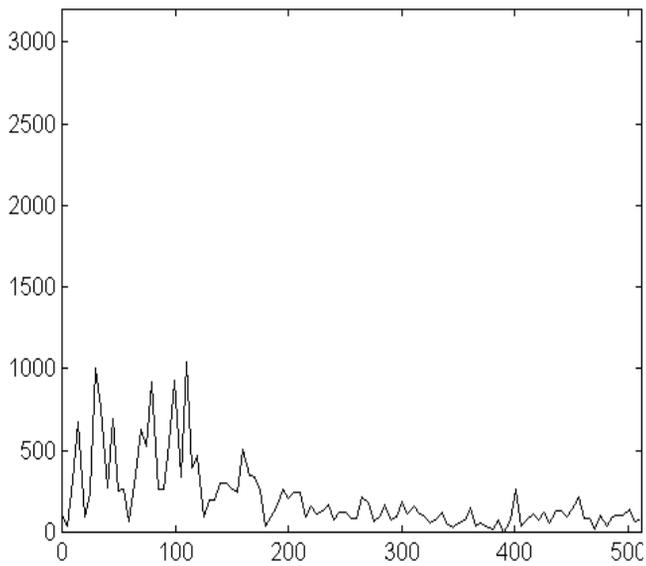
Arquitectura propuesta



Biomedida

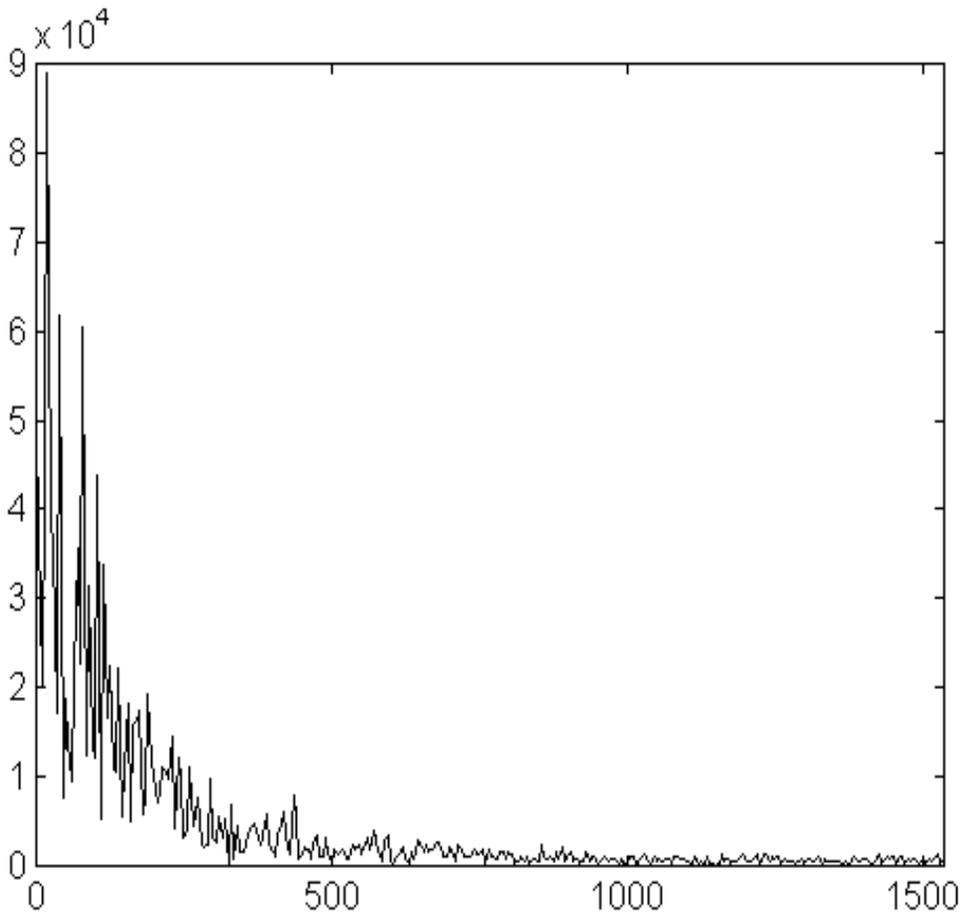


Parámetros: Filtro de red.

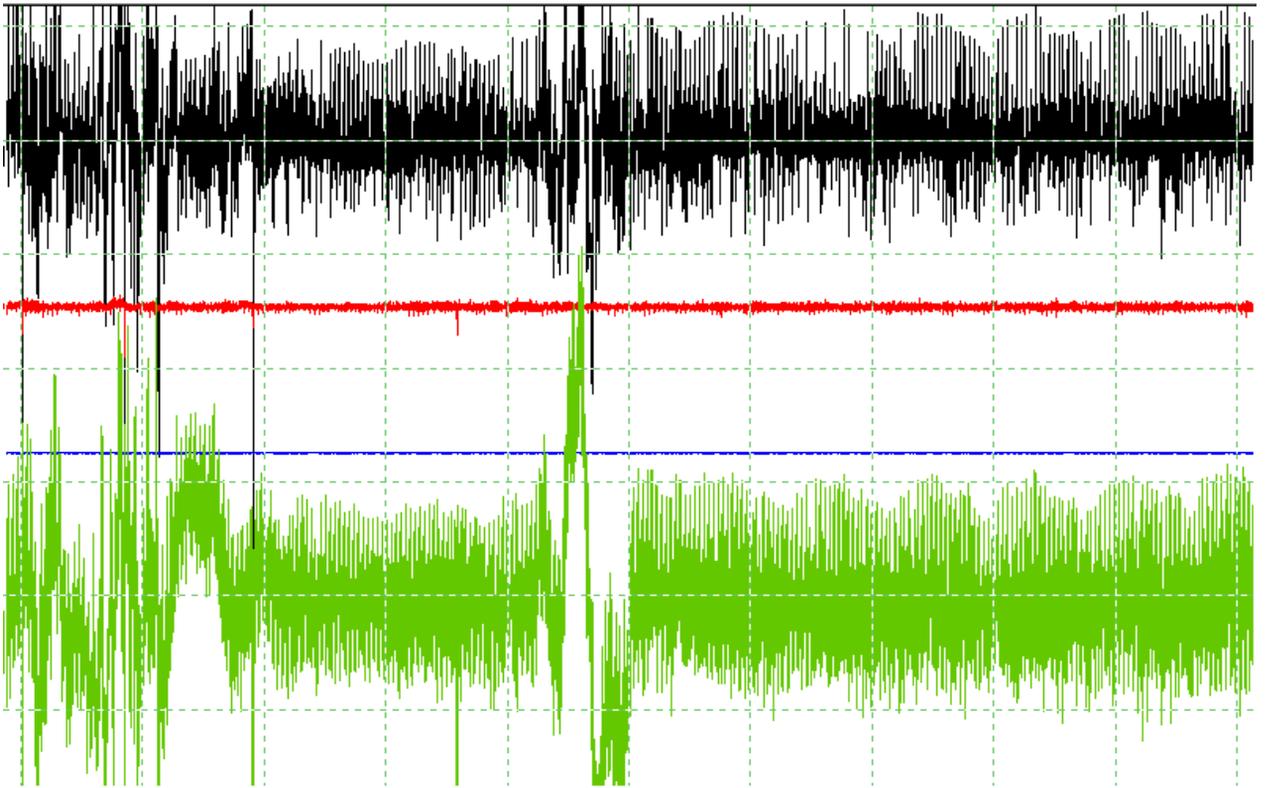


Parámetros (II): frecuencia de muestreo

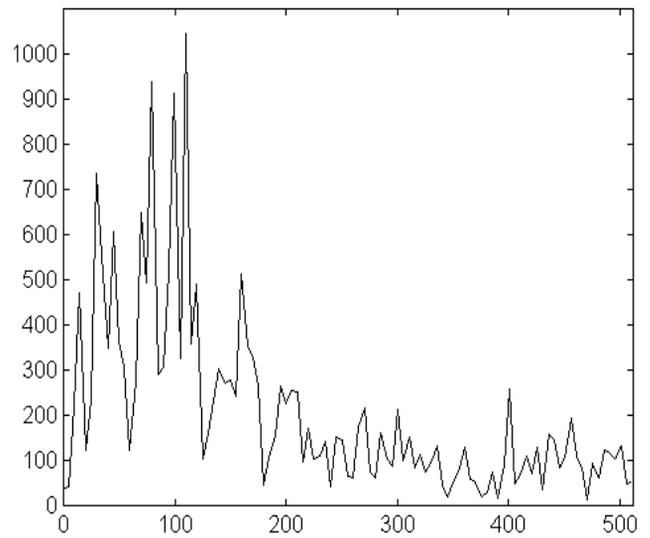
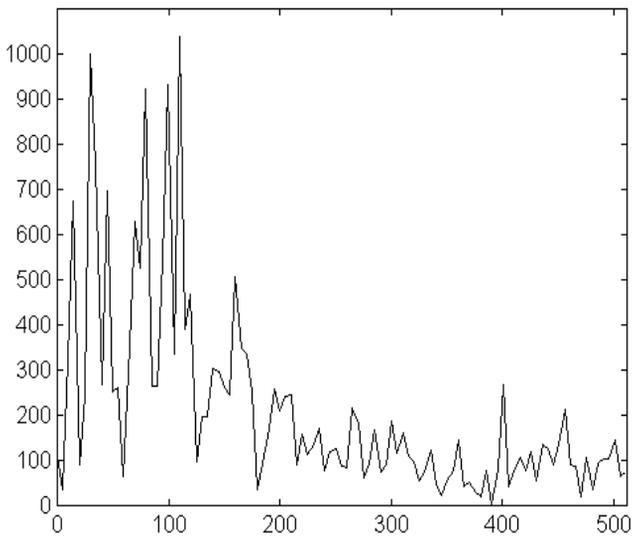
⌘ El 95% de la energía cae bajo los 512Hz



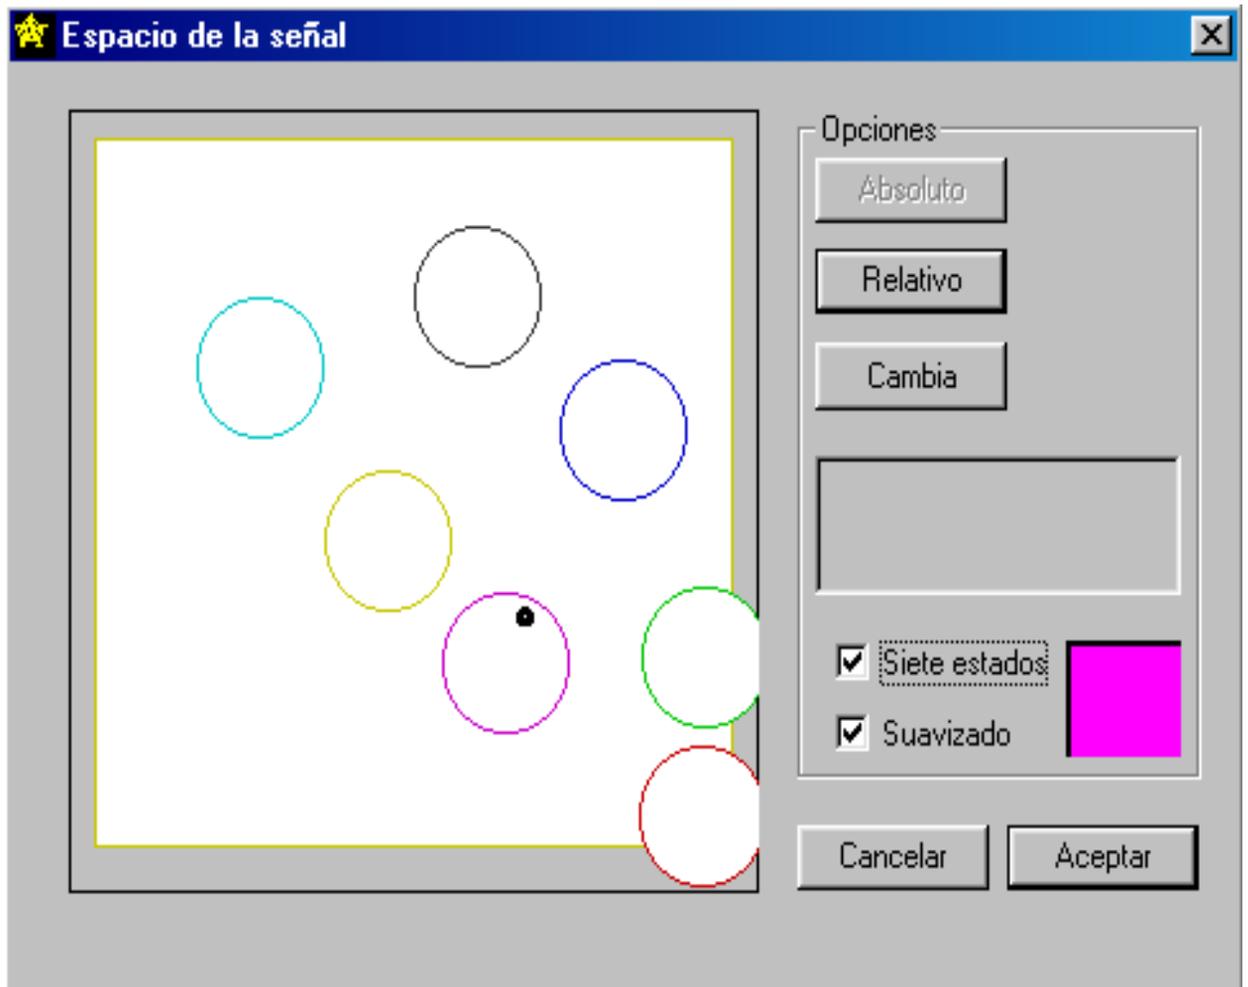
Parámetros (III): Filtros DC y medianas



Parámetros (IV): Filtro FIR paso alto



Espacio (I)



Espacio (II)



Futuras líneas.

Mejoras:



- ⌘ Del sistema: aprovechar info. temporal
- ⌘ Del clasificador: red neuronal
- ⌘ Del extractor: transformada Wavelet
- ⌘ Del procesado: mejores filtros
- ⌘ Del hardware: elec. activos, más canales
- ⌘ Detección de la co-contracción
- ⌘ Miniaturización del sistema
- ⌘ Creación de aplicaciones nuevas

Preguntas

