

# Tema 8

## Sistemas de Análisis

### 8.1. Introducción

Los sistemas de análisis automático basados en técnicas modernas de análisis de patrones comienzan a desarrollarse a mediados de la década de 1960. El objetivo es enseñar al sistema a manejar la información de interés presente en la señal de forma que reconozca o analice los patrones característicos que permiten al experto humano realizar un diagnóstico.

Los patrones son porciones específicas de la señal, caracterizados por su morfología o por determinados parámetros característicos (tales como la frecuencia, amplitud, etc.). Los patrones están generados por eventos fisiológicos o por propiedades del medio de conducción. El análisis de patrones incluye:

- Reconocimiento: comprende las diferentes fases de procesado desde la adquisición hasta la identificación del patrón, y se utiliza para tareas de clasificación (asignación de un patrón a una clase determinada) o detección (determinación del instante de ocurrencia o localización espacial de un patrón).
- Interpretación: es el reconocimiento de las implicaciones que la aparición del patrón tiene (por ejemplo, el origen o la forma de generarse eventos, etc.). Utiliza resultados obtenidos en diferentes etapas del reconocimiento de patrones.
- Aprendizaje: incluye las diferentes etapas durante las cuales se transfiere conocimiento a la máquina, con el objetivo de minimizar el error durante el reconocimiento o la interpretación. Este aprendizaje puede ser supervisado o no supervisado. En el primer caso, se proporcionan patrones correctamente clasificados por los expertos para cada clase, y que permiten al sistema aprender la forma de clasificar. En el segundo caso, el sistema forma automáticamente grupos de patrones similares y extrae a partir de ellos las clases.

En este tema nos vamos a centrar en el reconocimiento de patrones. Dicho reconocimiento se realiza mediante un proceso de clasificación. El sistema tiene a priori un conocimiento de los tipos (clases) de señal a considerar, obtenido durante la fase de

aprendizaje. Una señal desconocida será clasificada en una de las clases conocidas. Una de estas clases suele ser una clase “desconocida”, que comprende todas aquellas opciones no consideradas, o también aquellos casos que no es capaz de clasificar. La entrada al sistema de reconocimiento es un conjunto de  $N$  medidas realizadas sobre el vector  $X$  (usualmente las muestras de la señal), y denominado “vector patrón”. Dicho vector contiene toda la información disponible de la señal. Un conjunto de características, estructuradas en forma de vector de características  $\beta$ , se extrae del vector patrón. El clasificador opera sobre el vector de características, con un conjunto de funciones denominadas “decisiones” o “funciones discriminantes” para obtener la clasificación.

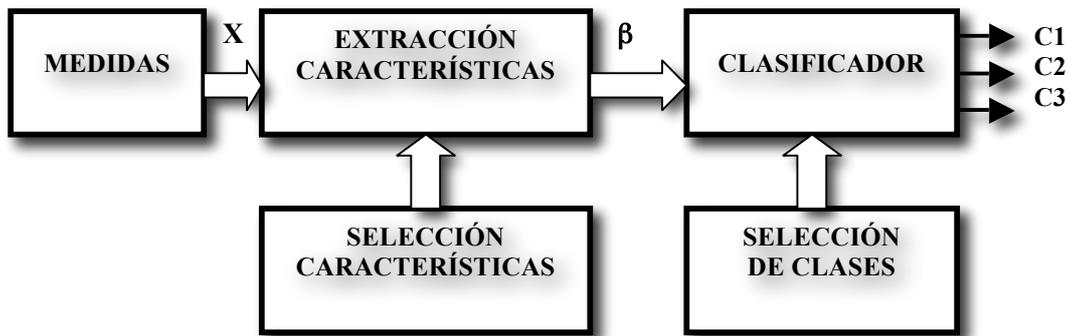


Figura 8.1. Diagrama de bloques de un sistema de clasificación.

El proceso consta, pues, de dos partes:

- 1. Fase de aprendizaje. En esta fase, se dota al sistema de la información necesaria sobre:
  - Las características a seleccionar (aquéllas que mejor discriminan).
  - Las clases a clasificar (patrones obtenidos a partir de las características correspondientes a cada clase, mediante una estimación de su probabilidad de distribución).
- 2. Fase de clasificación. En esta fase tenemos dos etapas:
  - Extracción de características a partir del vector patrón, en función de la información sobre selección de características.

- Clasificación, comparando los patrones de las clases con el vector de características mediante alguna función de decisión. En general, cuando existen  $M$  clases, se utilizan  $M$  funciones de decisión,  $d_i(\beta)$ ,  $i=1..M$ . La señal con vector patrón  $X$  y vector de características  $\beta$  se clasificará en la clase  $i$ -ésima,  $w_i$ , si:

$$d_i(\beta) > d_j(\beta); \quad i, j = 1, \dots, M; \quad i \neq j$$

En el siguiente ejemplo, tenemos un vector de características de dimensión 3, y dos clases  $\omega_1$  y  $\omega_2$ . La proyección de los grupos de características en el espacio tridimensional de características se muestra en la siguiente figura. Puede verse que la clasificación de las dos clases se puede hacer con la característica  $\beta_2$  solamente, puesto que las proyecciones de los grupos en este eje no se solapan, cosa que ocurre para los otros casos. Por tanto puede establecerse una función de decisión que discrimine entre ambas clases.

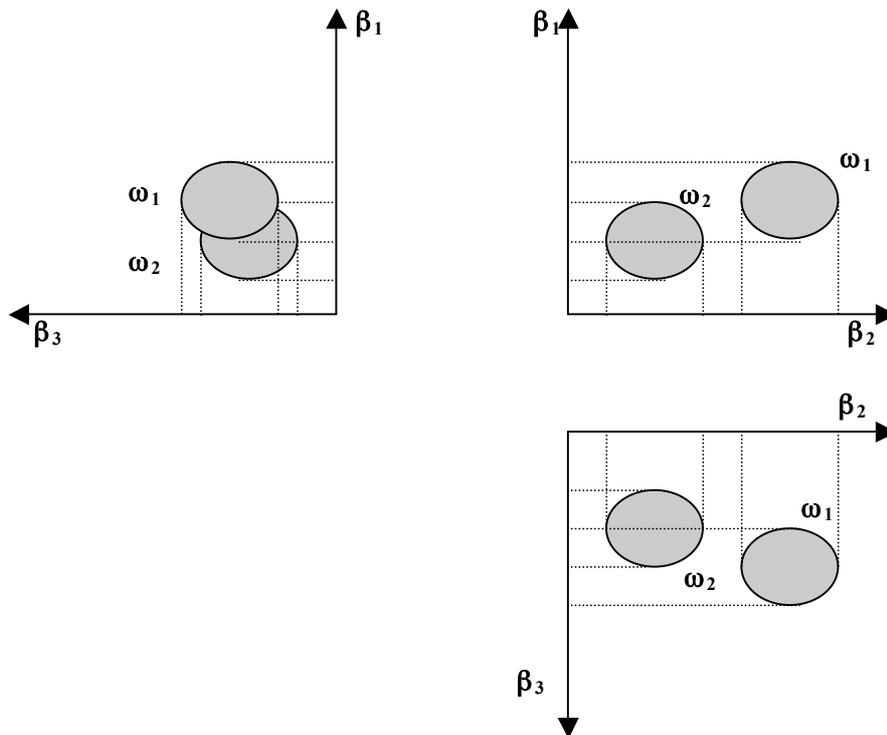


Figura 8.2. Proyección de los grupos en el espacio de características.

En las siguientes secciones, vamos a revisar los métodos de extracción de características y clasificación más usuales.

## 8.2. Extracción de características

Las características son representaciones compactas de los patrones conteniendo, idealmente, sólo información relevante para su clasificación. La elección óptima de características para un determinado caso no es obvia, y generalmente se realiza basándose en el conocimiento previo de que se dispone sobre el problema. Esto crea un cierto grado de incertidumbre en la selección, frecuentemente resuelta mediante métodos de prueba y error, y también suele generar un número inicialmente grande de características seleccionadas, que puede reducirse mediante algunas técnicas.

Las características se organizan usualmente como un vector (vector de características), que constituye una representación comprimida del patrón. La dimensión de dicho vector viene limitada por diversos factores contrapuestos, como la complejidad del *hardware* o el *software* del clasificador, el hecho de que la clasificación sea más precisa cuando el vector de características sólo contiene las más relevantes o la máxima pérdida de información permisible. A continuación comentaremos brevemente diversas técnicas de extracción y selección de características.

### Características no transformadas

Son características extraídas directamente de los datos de entrada, como amplitudes, duraciones, etc. Un tipo usual es el cálculo de momentos de diferentes órdenes, tales como el de primero (media), el de segundo (potencia de la señal) y el segundo momento central (desviación estándar).

Otro tipo es el modelado paramétrico. En este caso, las características serían los coeficientes autorregresivos y de promediado móvil del modelo.

### Características transformadas

Se trata de características extraídas por transformación de los datos (aplicación de una transformada). La más común es la transformada discreta de Fourier (DFT), utilizada en análisis espectral y que permite extraer características frecuenciales de la señal. Otras transformadas, como la transformada discreta del coseno (DCT), la de Haar o la de Walsh,

o en el caso de las *wavelets*, como transformaciones de la señal en un plano tiempo-escala, se han utilizado para extraer características de bioseñales.

La transformada de Karhunen-Loève (KLT) proporciona una representación de una señal en función de una base ortonormal de vectores ordenados, donde cada vector de la base representa características relevantes de la misma. Puesto que los vectores están ordenados óptimamente, la selección de características (vectores de la base) se realiza simplemente escogiendo los N primeros, de mayor magnitud, y desechando el resto. No obstante, si dos clases comparten las características más relevantes y sólo se diferencian en algunas menos relevantes, se perdería la información discriminativa. Algunos autores proponen realizar algún tipo de transformación a los datos antes de aplicar la KLT en estos casos.

Un método eficiente de extracción de características es el de descomposición en valores singulares (SVD). Se trata de una extensión de la KLT al caso de varias señales de entrada, ordenadas en forma de matriz, e intenta representar la matriz de datos como otra matriz de menor rango. Los valores singulares son las raíces cuadradas positivas de los valores propios del producto de la matriz de datos por su transpuesta, y están ordenados de mayor a menor, por lo que también puede seleccionarse un número N.

## Descriptores estructurales

Se utilizan en técnicas sintácticas de reconocimiento de patrones, basadas en la morfología de los mismos. La estructura del patrón está formada por una serie de características de bajo nivel, usualmente llamadas primitivas, tales como arcos, esquinas o líneas, que se caracterizan por una serie de medidas o atributos (grado de curvatura, longitud del arco, etc.).

La señal puede descomponerse en primitivas mediante la utilización de gramáticas. Una gramática viene definida por:

$$G = [ V_T, V_N, P, S ]$$

donde  $V_T$  es el conjunto de símbolos o primitivas terminales,  $V_N$  es el conjunto de símbolos no terminales, P son las producciones o reglas de reescritura de los símbolos y S es el símbolo inicial o raíz. Un alfabeto es el conjunto de todos los símbolos utilizados por la gramática, y un lenguaje está compuesto por todos los subconjuntos del vocabulario que puede generar la gramática. Una sentencia o cadena es cualquier secuencia de símbolos formado a partir del vocabulario.

La figura 8.3 muestra un ejemplo de representación sintáctica del ECG y el conjunto de características (o primitivas) correspondiente. Por ejemplo, se podrían medir

atributos para cada primitiva tales como la suma de los valores de cada muestra o el número de muestras que la componen (relacionados, respectivamente, con la amplitud y duración correspondientes).

## Descriptores gráficos

Los gráficos se utilizan en técnicas sintácticas de reconocimiento de patrones cuando el conjunto de entrenamiento es demasiado pequeño para inferir correctamente las gramáticas correspondientes a las clases de patrones. Se definen como  $G_T = [N, R]$ , donde  $N$  es un conjunto de nodos (vértices en el patrón), y  $R$  es un subconjunto de  $N \times N$  que indica los arcos en el gráfico. Existen varios tipos: gráficos relacionales, acoplados y relacionales con atributos.

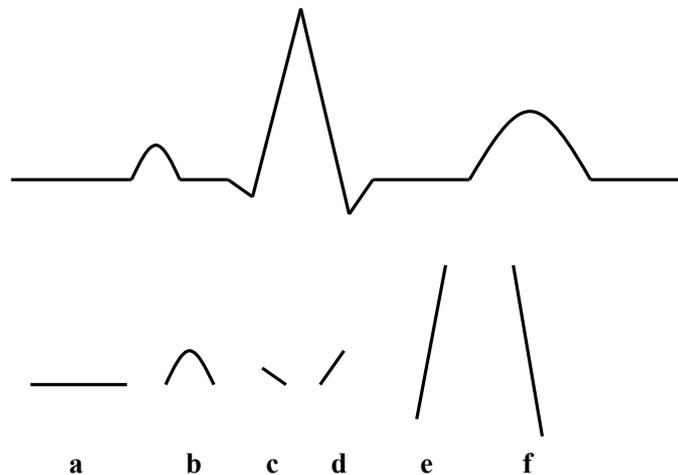


Figura 8.3. Representación sintáctica del ECG: definición de primitivas.

## Métodos de selección de características

La selección de características se suele basar en alguna medida de su efectividad. Una medida óptima es la probabilidad de error en la clasificación producido por el conjunto seleccionado. Otra medida utilizada en la práctica es el porcentaje de error obtenido tras realizar la clasificación del conjunto de datos disponibles. También se utilizan las matrices de dispersión, tanto la correspondiente a los elementos de la misma clase (definida como la matriz de covarianza de las características de esa clase), como la de dispersión entre clases (correspondiente a la covarianza entre clases). En este caso, el

criterio de separabilidad es proporcional a ambas matrices, y debe maximizarse para maximizar la distancia entre las clases sin aumentar la dispersión dentro de cada una.

Dado el conjunto inicial de características extraídas, puede calcularse el criterio para todas las combinaciones posibles de las mismas. Este método, que se conoce como búsqueda exhaustiva, tiene como inconveniente la gran cantidad de cálculos a realizar (por ejemplo, el número de combinaciones a calcular es el orden de  $10^7$  para un número de características de 40). En la práctica se utilizan otros métodos subóptimos, tales como la búsqueda hacia delante o hacia atrás. En la primera, se selecciona la mejor característica, que se incorpora al conjunto final, inicialmente vacío. A continuación se busca la siguiente más discriminatoria, calculando en cada iteración el criterio de clasificación. En la búsqueda hacia atrás se parte de un conjunto inicial que contiene todas las características y en cada iteración se va eliminando una de ellas.

La limitación que presentan estos algoritmos es la imposibilidad de descartar o reintroducir características, consideradas no relevantes en su momento, en el conjunto final. Otra técnica, conocida como algoritmo *añadir l y descartar r*, combina los dos métodos anteriores, eliminando r características del conjunto final después de haber añadido l nuevas.

Otro método de reducción de la dimensión del vector de características es el utilizado en análisis discriminante, que determina en menor conjunto de características posible minimizando la varianza entre grupos mediante la utilización del estadístico F como índice de bondad.

### 8.3. Métodos de clasificación

El proceso de clasificación requiere que los vectores de entrenamiento estén agrupados en clases bien definidas y separables en el espacio de características. Este agrupamiento en clases se conoce como *clustering*, y existen diversas técnicas para implementarlo, tanto en aprendizaje supervisado (en el que ya existe una asignación previa de cada vector de entrenamiento a una clase, aunque dicha asignación pueda no ser correcta) como automático (en el que el propio sistema debe generar la asignación).

Existe una gran variedad de métodos de clasificación, que podemos agrupar en clasificadores estadísticos, sintácticos y basados en técnicas de Inteligencia Artificial. A continuación comentaremos brevemente estos métodos.

## Clasificadores estadísticos

Existen varios tipos de clasificadores estadísticos. Un tipo, los denominados clasificadores basados en minimización de distancias, realizan la clasificación de un patrón en función de la menor distancia a una de las clases en el espacio de características.

Dentro de este tipo se encuentra el clasificador lineal de Bayes. Supone conocidas las probabilidades asociadas a cada clase,  $P(\omega_i)$ . Por ejemplo, para el caso de dos clases,  $\omega_1$  y  $\omega_2$ , suponiendo matrices de covarianza iguales y características estadísticamente independientes, para las cuales la inversa de la matriz de covarianza es la matriz identidad, la regla de decisión de Bayes simplificada clasifica el vector de características  $\beta$  según:

$$(\bar{\mu}_2 - \bar{\mu}_1)^T \cdot \beta + \frac{1}{2} (\bar{\mu}_1^T \bar{\mu}_1 - \bar{\mu}_2^T \bar{\mu}_2) < \ln \left[ \frac{P(\omega_1)}{P(\omega_2)} \right] \Rightarrow \beta \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

donde  $\mu_1$  y  $\mu_2$  son los vectores de las medias de cada clase.

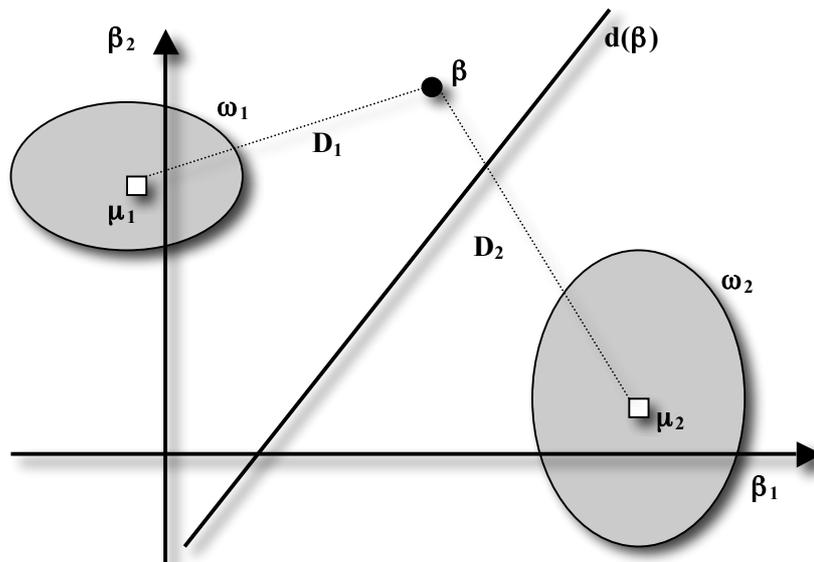


Figura 8.4. Clasificador de distancia mínima.

Cuando las clases están bien separadas entre sí, puede realizarse la clasificación en función de la distancia mínima del vector de características a una de las clases. La siguiente figura muestra un ejemplo de clasificador de distancia mínima. Las dos clases

son separables mediante una función de decisión  $d(\beta)$ . Dado el vector  $\beta$ , se calculan las distancias  $D_1$  y  $D_2$ , asignando el vector a la clase a la que corresponda menor distancia.

El clasificador de distancia euclídea utiliza una regla de decisión dada por:

$$\| \bar{\beta} - \bar{\mu}_1 \|^2 - \| \bar{\beta} - \bar{\mu}_2 \|^2 \begin{matrix} < \\ > \end{matrix} 2 \ln \left[ \frac{P(\omega_1)}{P(\omega_2)} \right] \Rightarrow \bar{\beta} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

La distancia euclídea se define como:

$$D_i^2 = \| \bar{\beta} - \bar{\mu}_i \|^2 = (\bar{\beta} - \bar{\mu}_i)^T \cdot (\bar{\beta} - \bar{\mu}_i)$$

y la función de decisión viene dada por:

$$d_i(\beta) = \beta^T \mu_i - \frac{1}{2} \mu_i^T \mu_i$$

La distancia de Mahalanobis es una variante de la anterior, normalizada respecto a la dispersión entre clases. Se define como:

$$D_i^2 = (x - \mu_i)^T (\Sigma)_i^{-1} (x - \mu_i)$$

donde  $\Sigma_i$  es la matriz de covarianza de la clase  $i$ .

En muchas ocasiones, las probabilidades de las clases no se conocen previamente, por lo que no pueden aplicarse los métodos anteriores. En este caso, se pueden utilizar técnicas no paramétricas, como la clasificación por el vecino más próximo. Supongamos, por ejemplo, el caso de dos clases,  $\omega_1$  y  $\omega_2$ . Dado el vector de características a clasificar,  $\beta$ , se fija un número  $k$  de vecinos próximos (correspondientes a los vectores de las dos clases), y se determina la región mínima del espacio de características, centrada en  $\beta$ , que contiene los  $k$  vecinos. Este número  $k$  a su vez estará formado por  $k_1$  vectores pertenecientes a  $\omega_1$  y  $k_2$  vectores de  $\omega_2$ , de manera que  $k = k_1 + k_2$ . La regla de clasificación para este caso vendrá dada por:

$$k_1 \begin{matrix} > \\ < \end{matrix} k_2 \Rightarrow \vec{\beta} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

La figura 8.5 muestra un ejemplo de este tipo de clasificador. En este caso,  $k=8$ ,  $k_1=6$  y  $k_2=2$ , por lo que  $\beta$  se clasificaría como perteneciente a la clase  $\omega_1$ .

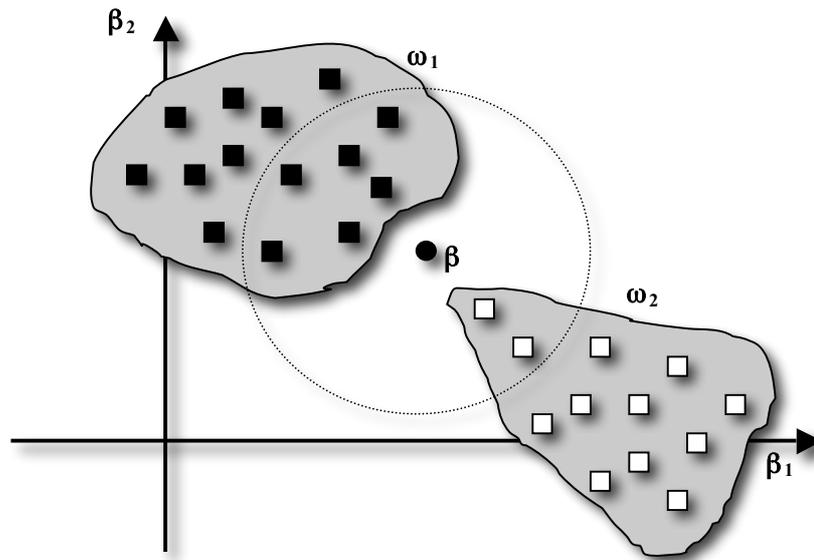


Figura 8.5. Ejemplo de clasificación por k vecinos más próximos.

Otro tipo de clasificador es el discriminante lineal de Fisher, que permite reducir la dimensión del vector de características de  $N$  a  $L=M-1$ , donde  $M$  es el número de clases. Para ello, se proyecta el vector original de dimensión  $N$  en una superficie de menor dimensión, elegida de manera que maximiza la separación entre clases, mejorando así la clasificación.

Los clasificadores basados en criterios de entropía realizan la clasificación de un patrón minimizando el grado de incertidumbre, lo que es equivalente a minimizar la dispersión dentro de cada clase mientras se preserva la dispersión entre las diferentes clases. Por último, los clasificadores basados en máxima semejanza, optimizan un parámetro basado en la semejanza entre el patrón a clasificar y el de las clases.

## Clasificadores sintácticos

Los clasificadores sintácticos siguen un esquema similar al de los estadísticos. Dado un conjunto de clases, el clasificador debe aprender su estructura durante la fase de aprendizaje. Para ello, partiendo de un conjunto de entrenamiento, se determinan las características estructurales (primitivas) y las reglas de combinación (gramática). Cada gramática describe todas las señales (sentencias) pertenecientes a una clase dada (lenguaje). La determinación de la gramática a partir del conjunto de entrenamiento se conoce como inferencia gramatical. En la fase de clasificación, el vector de entrada se preprocesa para eliminar ruido y se extraen sus primitivas. Posteriormente se clasifica

mediante la aplicaci3n de la gramàtica de cada classe. El esquema del proceso puede verse en la siguiente figura.

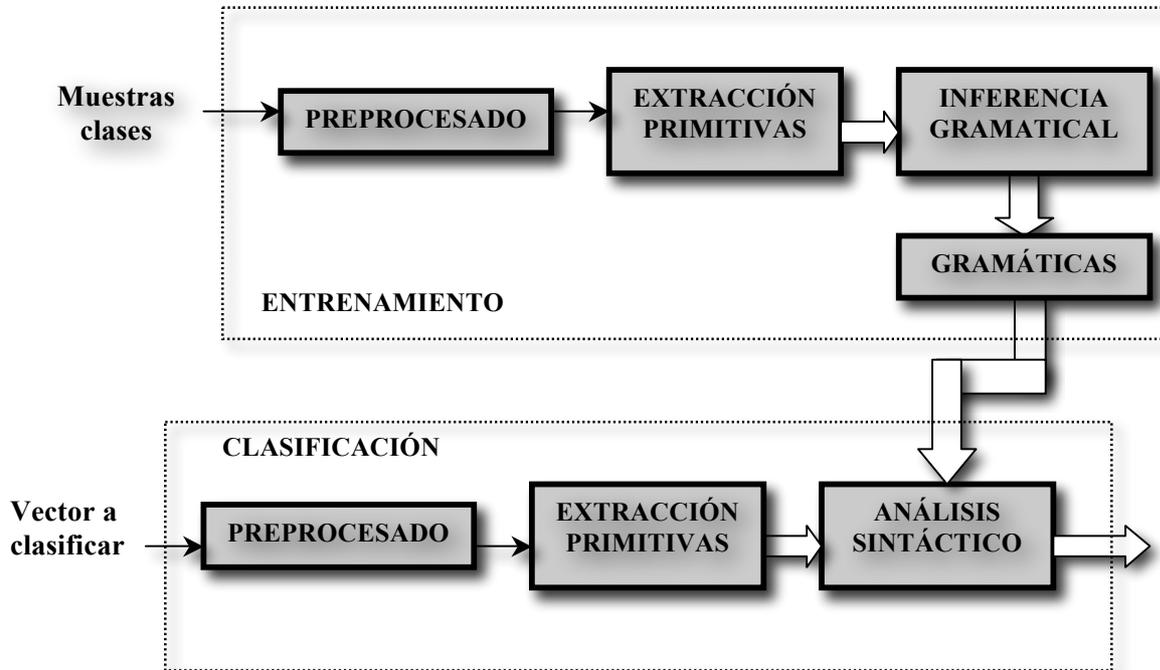


Figura 8.6. Diagrama de bloques de un sistema de clasificaci3n sintàctica.

El vector a clasificar està representado por una cadena, una lista de s3mbolos que representan primitivas de la se1al conectadas en un orden espec3fico, generada por una gramàtica. Cada clase tiene su propia gramàtica, y el clasificador debe determinar cuàl ha producido dicha cadena. Un m3todo usual de reconocimiento de cadenas es la utilizaci3n de aut3matas de estados. Un aut3mata de estados finitos viene dado por:

$$A = (\Sigma, Q, \delta, q_0, F)$$

donde  $\Sigma$  es el alfabeto,  $Q$  es el conjunto de estados,  $\delta$  es el operador de mapeado,  $q_0$  es el estado inicial y  $F$  el conjunto de estados finales.

Como ejemplo, consideremos el anàlisis sintàctico de la se1al de ECG propuesta por Furno y Tompkins (figura 8.7). En este caso, se utiliza un aut3mata para clasificar complejos QRS (detecci3n del QRS). El aut3mata viene definido por:

$$A_E = (\Sigma_E, Q_E, \delta, q_0, \{q_Q, q_N\})$$

donde

$$\Sigma_E = \{ \text{cero}, \text{normup}, \text{normdown}, \text{otro} \}$$

$$Q_E = \{ q_0, q_1, q_2, q_Q, q_N \}$$

$q_Q$  y  $q_N$  son los estados finales (QRS o ruido). Las reglas de transición entre estados vienen dadas por el operador de mapeado  $\delta$ , y son del tipo:

$$\delta(q_0, \text{cero}) \rightarrow \{ q_0 \}$$

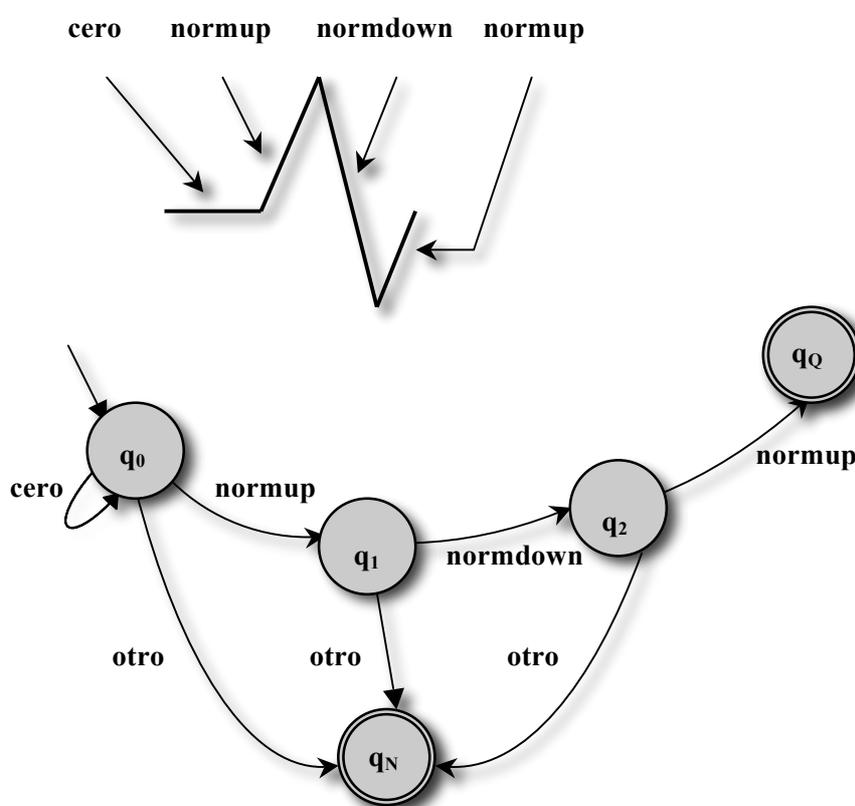


Figura 8.7. Definición de primitivas y diagrama de transición de estados.

Para calcular las primitivas, se deriva la señal de entrada. Posteriormente se agrupa la derivada en secuencias de valores consecutivos con igual signo de la derivada. A cada secuencia se le asocian dos parámetros: la suma de las diferencias entre muestras (relacionado con la amplitud de la secuencia) y el número de diferencias (relacionado con

la duración de la misma), cuyos valores normales se obtienen en la fase de aprendizaje. Aplicando umbrales, se determina el tipo de primitiva extraído (por ejemplo, si es una pendiente normal –normup-, línea basal –cero- o ruido –otro-). La cadena de primitivas obtenida será la entrada al autómata, que determinará si se trata de un QRS normal (secuencia cero-normup-normdown-normup) o no. La figura 8.7 muestra la definición de primitivas y el diagrama de transiciones entre estados.

## Clasificadores basados en técnicas de inteligencia artificial

Básicamente hay dos grupos de técnicas basadas en inteligencia artificial (AI): simbólicas (sistemas expertos) y conectivas (redes neuronales). Un sistema simbólico es un mecanismo de manipulación de información sobre la estructura de las clases. Un tipo usual en reconocimiento de patrones biomédicos es el sistema experto, que se basa en razonamiento de tipo inductivo y bases de conocimiento para realizar la clasificación.

Para implementar el razonamiento, se utilizan procedimientos basados en reglas. Las reglas representan conocimiento sobre el problema, codificado en una serie de instrucciones. Por ejemplo, una regla de decisión típica en un sistema de análisis de ECG puede tener el siguiente formato:

```
REGLA nnn: IF
    (1) QRS  $\geq$  110 mseg en cualquier derivación AND
    (2) Sd.  $\geq$  40 mseg. en I o avL AND
    (3) R terminal presente en V1
THEN
    (a) QRS = 0.11 seg; AND
    (b) QRS terminal hacia la derecha y anterior; AND
    (c) bloqueo incompleto rama derecha haz.
```

Las reglas están usualmente basadas en conocimiento de expertos humanos. El camino a través del árbol de decisión proporciona finalmente una o más interpretaciones que son presentadas en un informe final. La aplicación de las reglas está controlada por especificaciones procedurales (metarreglas). Las estrategias de control de los sistemas expertos se basan en motores de inferencias, que interconectan las reglas con los datos. Podemos destacar dos tipos: los que proporcionan una conclusión (clasificación) a partir de un conjunto de hechos (datos) y reglas, y los que muestran que un conjunto de hechos satisfacen las hipótesis.

## Clasificadores basados en redes neuronales

Las redes neuronales (RN) son sistemas conectivos que simulan las conexiones entre neuronas biológicas y sus características de activación. Su clasificación se basa en la topología de la red (número de neuronas, de capas e interconexiones de las mismas), así como en el modo de aprendizaje. Este tipo de clasificadores se distingue del resto de los comentados en que no es algorítmico, y la información aprendida durante el entrenamiento se utiliza para modificar la propia topología de la red.

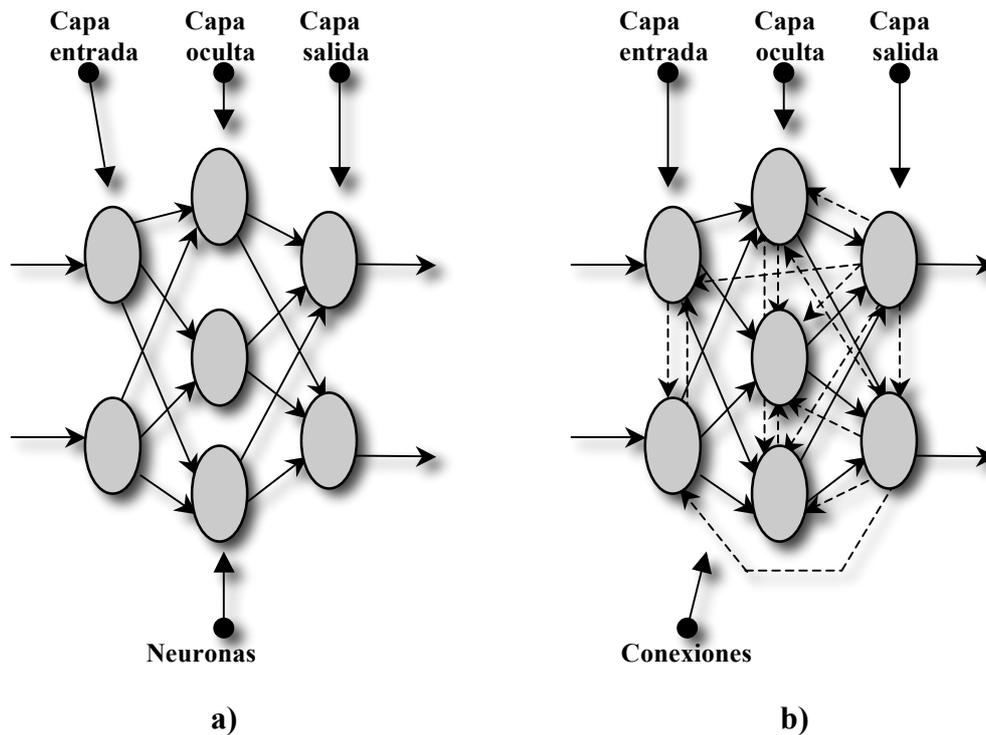


Figura 8.8. Estructuras de redes neuronales: a) red tipo *feedforward*; b) red tipo Hopfield.

Existen básicamente dos tipos de estructuras: *feedforward* y Hopfield. La red *feedforward* consiste en varias capas formadas por diverso número de neuronas artificiales. Las conexiones entrantes a cada capa provienen exclusivamente de la capa anterior, y las salientes sólo llegan a la siguiente. La primera capa se denomina *capa de entrada*, la última *capa de salida* y el resto *capas intermedias u ocultas*. Las redes de tipo Hopfield se diferencian de las *feedforward* en que puede haber conexiones desde capas posteriores a anteriores (no necesariamente consecutivas) y las salidas pueden obtenerse también de las

capas ocultas, y no necesariamente de la última capa. La figura 8.8 muestra ambos tipos de esquemas.

La estructura de una neurona artificial (perceptrón) se muestra en la siguiente figura. Las  $n$  entradas, equivalentes a las sinapsis de la neurona real,  $e_n$ , se multiplican por  $n$  factores peso,  $\omega_n$ , y posteriormente se suman. La salida depende de una función de activación,  $F$ , que puede ser lineal o no (las más usuales en este caso son la función umbral y la sigmoide).

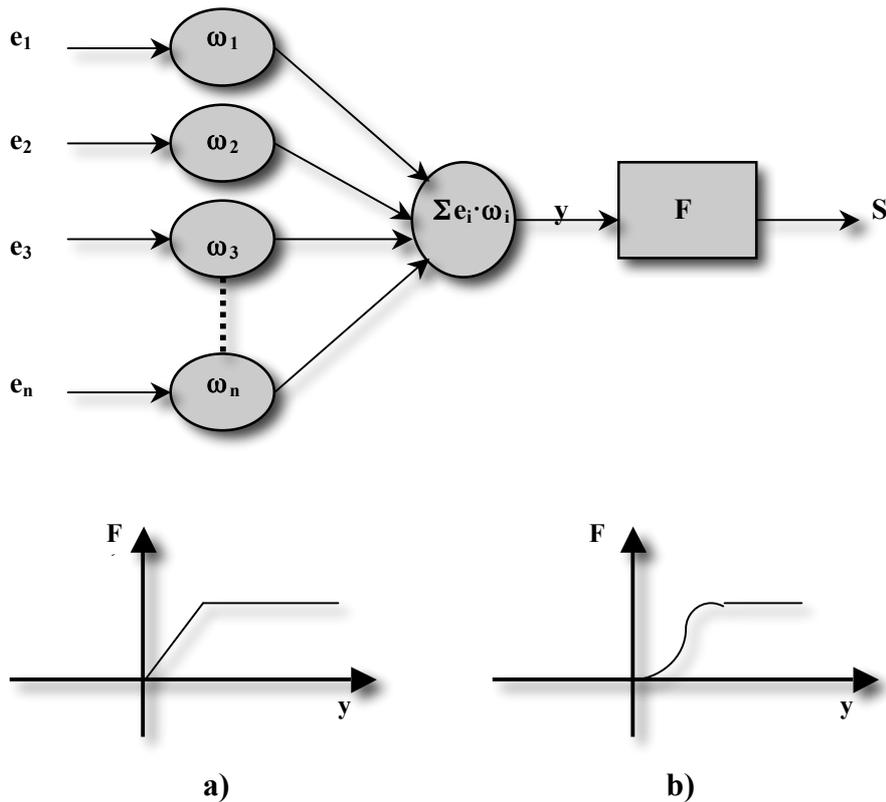


Figura 8.9. Estructura de una neurona y funciones de activación: a) umbral; b) sigmoide.

En la fase de entrenamiento, se utilizan algoritmos como el *back-propagation*, que modifican iterativamente los pesos de cada capa para proporcionar la salida deseada a partir del conjunto de entrenamiento.

## 8.4. Evaluación de clasificadores

Una vez desarrollado el clasificador, debe evaluarse su funcionamiento antes de su utilización. El método de evaluación usual es similar al que se aplica para la evaluación de pruebas diagnósticas en medicina, ya que el objetivo del sistema de clasificación es también “diagnosticar” el tipo de patología que padece el paciente. No obstante, el método puede extrapolarse no sólo al caso de sistemas de clasificación, sino también al caso de detectores de eventos o cualquier otro sistema que deba decidir entre varias opciones.

La exactitud de una prueba diagnóstica se define como la capacidad de clasificación correcta. No obstante, pueden darse diferentes casos cuando aplicamos la prueba:

- Verdadero positivo (VP): el resultado de la prueba coincide con la clasificación correcta, indicando la presencia de la patología real.
- Verdadero negativo (VN): el resultado de la prueba coincide también con la clasificación correcta, indicando en este caso la ausencia de patología.
- Falso positivo (FP): el resultado de la prueba no coincide con la clasificación correcta, indicando presencia de una patología que no existe en realidad.
- Falso negativo (FN): el resultado de la prueba no coincide con la clasificación correcta, indicando ausencia de una patología que sí existe en realidad.

En base a estos casos, podemos definir diversos parámetros que permiten evaluar la prueba diagnóstica. Los más usuales son:

- Sensibilidad: indica la capacidad de la prueba para detectar la presencia de la patología. Se define como:

$$\text{Sensibilidad} = \text{VP} / (\text{VP} + \text{FN})$$

- Especificidad: indica la capacidad de la prueba para no detectar la presencia de la patología cuando no está presente. Se define como:

$$\text{Especificidad} = \text{VN} / (\text{VN} + \text{FP})$$

- Valor predictivo positivo: proporción de resultados válidos entre los resultados positivos de la prueba. Se define como:

$$\text{VPP} = \text{VP} / (\text{VP} + \text{FP})$$

- Valor predictivo negativo: proporción de resultados válidos entre los resultados negativos. Se define como:

$$VPN = VN / ( VN + FN )$$

- Valor global: proporción de resultados válidos entre todos los resultados. Se define como:

$$VG = ( VP + VN ) / ( VP + FP + VN + FN )$$

En el caso ideal, los valores de los parámetros deberían tender al 100%. Los valores inferiores que se obtienen generalmente están influidos no sólo por el rendimiento del propio sistema de clasificación, sino también por la elección de la muestra de casos sobre la que se aplica. Dicha muestra se divide usualmente en dos grupos: control (que corresponde a personas sanas que no presentan patologías) y el de pacientes afectados por la patología. La composición del grupo control influye en la especificidad obtenida, mientras que la del grupo de pacientes condiciona el valor de sensibilidad. También los valores predictivos se ven afectados por factores como la prevalencia de la enfermedad, es decir, la frecuencia de afectación de dicha enfermedad en el conjunto de la población.

Otro factor importante en la evaluación de la prueba es disponer de un diagnóstico fiable de referencia, lo que se conoce como estándar de oro. Para su obtención, se debe definir un criterio que pueda ser aplicado por un grupo de expertos para llegar a un consenso en el diagnóstico final. Existen bases de datos estándar que proporcionan ficheros de marcas de referencia que permiten evaluar algoritmos de detección o clasificación. Por ejemplo, algunas de las más utilizadas para ECG son la del Instituto Tecnológico de Massachussets (MIT/BIH) o la de la Asociación Americana del Corazón (AHA).

Por último, la decisión de clasificación se establece mediante la utilización de algún tipo de umbral sobre los resultados de las pruebas realizadas. Esto implica que, dependiendo del mismo, se obtienen diferentes resultados de sensibilidad y especificidad para un determinado método. Las denominadas curvas ROC (*Receiver Operating Characteristics*), desarrolladas inicialmente en aplicaciones de radar, se comenzaron a aplicar en el campo de la medicina para evaluar pruebas diagnósticas que presentan solapamientos de resultados entre pacientes y personas sanas. La curva ROC es un gráfico en el que se sitúa los valores de sensibilidad en el eje Y, y los de 1-especificidad en el eje X. Para el conjunto de casos se obtienen pares sensibilidad-especificidad que conforman la curva para diferentes valores de umbral. Para comparar métodos de clasificación, se obtienen las curvas correspondientes a cada método, siendo el óptimo aquél que presente la curva con mayor área encerrada. La figura 8.10 muestra un ejemplo de curvas ROC.

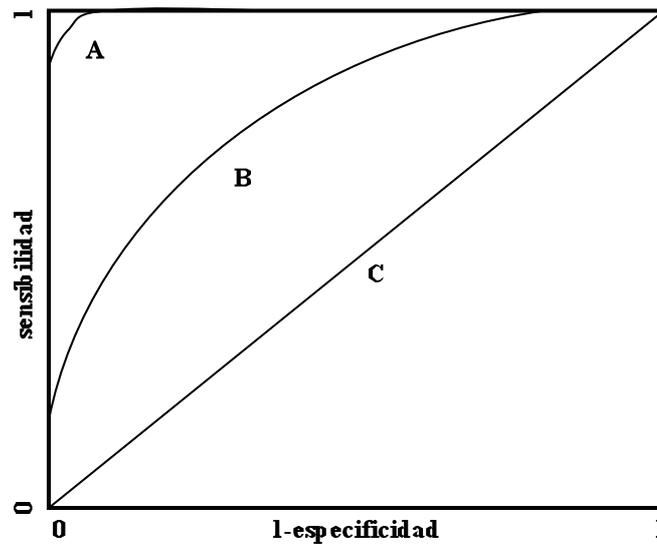


Figura 8.10. Curvas ROC. A: caso ideal (máxima área encerrada). B: caso intermedio. C: caso límite (sin discriminación).

## 8.5. Ejemplos de sistemas

### Analizador de ECG

Un sistema de análisis del ECG realiza una clasificación automática de señales electrocardiográficas. Aquí, las muestras serán registros de ECGs de casos normales y patológicos. Un conjunto de ECGs es previamente diagnosticado manualmente por el cardiólogo, y constituye el conjunto de entrenamiento. De este conjunto, se generan patrones (para cada una de las clases) y se estiman las estadísticas asociadas a cada clase. Cuanto mayor sea la información contenida en el conjunto de entrenamiento, mejor será el proceso de entrenamiento y la probabilidad de una correcta clasificación.

La interpretación del ECG comienza, pues, con la extracción de características, proceso que podemos dividir en dos partes:

1. Reconocimiento de formas de onda para identificar las ondas del ECG, incluyendo ondas P, T y complejo QRS.

2. Medidas para cuantificar el conjunto de amplitudes y duraciones utilizadas para controlar el proceso de interpretación.

El primer paso en el reconocimiento de ondas es identificar los pulsos independientes utilizando un algoritmo de detección del QRS. En segundo lugar, los pulsos similares en cada canal son alineados temporalmente y promediados, produciendo un pulso patrón para cada una de las 12 derivaciones. Estos 12 patrones son analizados para identificar ondas adicionales u otras características del ECG, realizándose un conjunto de medidas que se disponen en una matriz para ser analizada por procesos subsiguientes. En la figura 8.11 se muestra la matriz de características que la máquina de análisis genera para cada paciente.

PA	70	127	77	10	50	102	90	90	80	87	80	70
PPA	-10		-15	-80	-25		-25	15		3		
EQD	5			108	10							
QD	17			88	17							
QA	80			665	125							
RD	71	49	18		71	18	23	28	49	52	88	88
SA	1340	340	170		1055	130	250	430	1040	1560	1130	820
SD		38	70			8	62	57	31	32		
SA		110	970			60	1020	1190	760	350		
RPD												
RPA												
SPD												
SPA												
DRSA	681	105	575	-399	823	-241	-783	-885	111	681	662	531
STU	35	7	-28	23	30	-10	42	70	55	12	10	20
STM	40	20	-20	-30	30		110	190	130	50	20	20
STE	50	30	-20	-40	35	-5	180	320	230	90	30	20
TA	230	120	-130	-170	175	-25	480	880	700	330	150	110
TPA												
MTA	180	90	-110	-140	130	-30	300	540	470	240	120	90
MXFC												

Figura 8.11. Matriz de medidas producida por una máquina de interpretación de ECG. Las amplitudes en mV y las duraciones en ms. (W. J. Tompkins Ed. "Biomedical Digital Signal Processing". Prentice Hall)

Existen dos aproximaciones básicas a la interpretación automática del ECG en instrumentación comercial: sistemas expertos (reglas de decisión) y clasificación estadística de patrones. En este sistema, se utiliza la primera aproximación. La siguiente figura muestra el informe final proporcionado al médico por un intérprete de ECG para el ECG presentado antes. La máquina ha clasificado este paciente como "Normal" con "Ritmo sinusal normal".

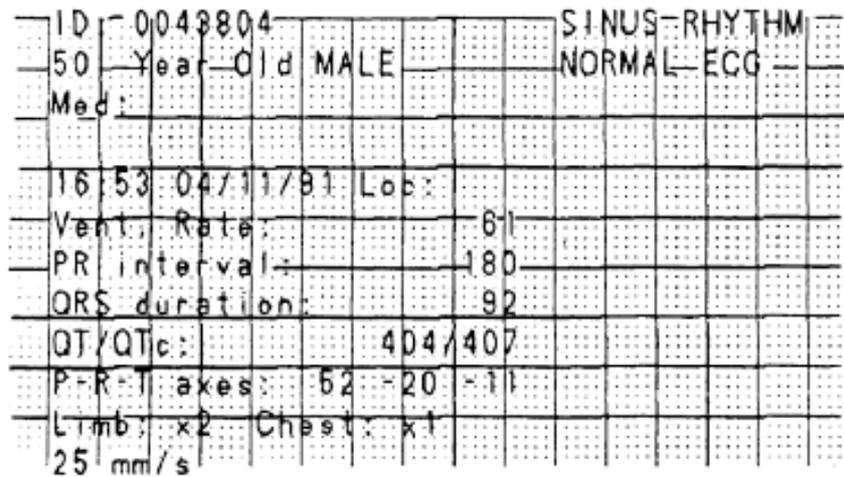


Figura 8.12. Sumario e interpretación (ángulo superior derecho) producido por un intérprete de ECG (*W. J. Tompkins Ed. "Biomedical Digital Signal Processing". Prentice Hall*).

## Monitor de arritmias

Un tema de creciente interés es el de monitorización de pacientes en su domicilio. El incremento de la capacidad de computación, con el decremento en tamaño y consumo, proporciona la posibilidad de diseñar instrumentación biomédica inteligente, que permita realizar funciones en el hogar hechas hasta ahora en hospitales.

El objetivo del monitor de arritmias es reemplazar las funciones de un grabador en cinta Holter, el dispositivo generalmente utilizado para determinar si un paciente ambulatorio tiene un problema cardíaco potencial. Un monitor portátil de arritmias inteligente captura el ECG durante los periodos supuestamente anormales y envía inmediatamente los registros parciales al hospital central a través de algún medio de transmisión, usualmente la red telefónica.

La extracción de características (en este caso, se utilizarán dos: intervalo RR y duración del QRS) requiere una detección previa de la onda R. La detección del QRS debe ser lo más precisa posible, puesto que de lo contrario los algoritmos de clasificación de arritmias producirán errores debido a pulsos detectados que no lo son realmente (falsos positivos) o a pulsos no detectados (falsos negativos). A partir de la detección del QRS pueden determinarse su duración y el intervalo RR.

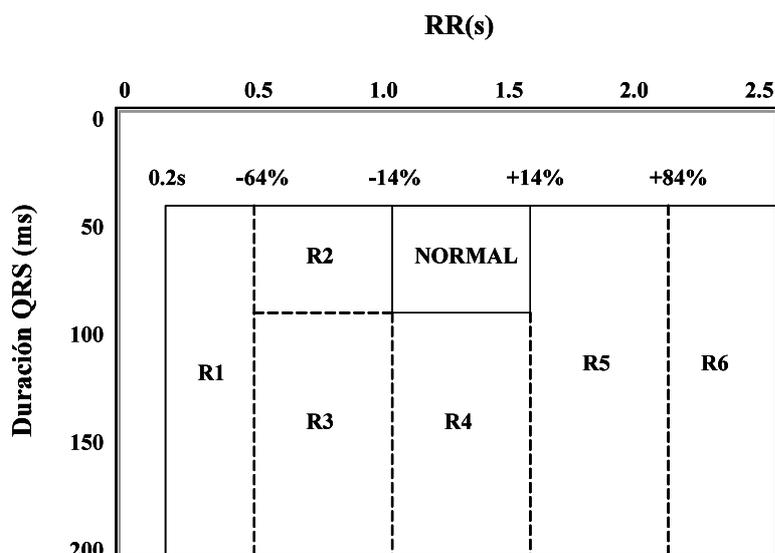


Figura 8.13. Definición de las clases en el espacio de características.

Para clasificar la señal de ECG, construiremos el espacio de características (en este caso, de dimensión 2), basándonos en la definición de las clases (figura 8.13). La región '0' (R0) tiene límites fijos basados en limitaciones fisiológicas. Cualquier vector de características representado en la región '0' se considera ruido, puesto que presenta valores de RR o duración del QRS inferiores a los posibles fisiológicamente.

Establecemos una región denominada normal, que será aprendida por el algoritmo basándose en un conjunto de 8 pulsos definidos por el cardiólogo como de ritmo y morfología normales para un paciente específico. Este proceso de aprendizaje establece el centro inicial de la región normal en el mapa bidimensional. Los límites de las otras regiones, excepto para la región '0', se obtienen como porcentajes de la localización del centro de la región normal.

El proceso de clasificación consistirá en representar el vector de características de la señal de entrada en el plano de características. La siguiente tabla muestra algunos tipos de patologías que puede detectar el sistema. Así, una taquicardia se caracterizará por series de pulsos en la región '1', que representa intervalos RR muy cortos. En caso de braquicardia, los pulsos caen en la región '6'. Las patologías pueden clasificarse también considerando secuencias de pulsos. Por ejemplo, una contracción ventricular prematura con pausa compensatoria completa podría caracterizarse por un intervalo RR corto y una duración del QRS larga seguido por un intervalo RR largo y una duración QRS normal. Esto podría manifestarse como una secuencia de dos puntos en el mapa, el primero en la región '3' y el segundo en la '5'.

TIPO	DESCRIPCIÓN
Normal	Pulso en la región normal.
Asistole	No hay R para $> 1.72$ seg ( $< 35$ ppm).
<i>Dropped</i>	RR largo: pulsos en R6.
R sobre T	Un pulso en R2.
PVC con pausa compensatoria	Un pulso en R3 seguido de otro en R5.
PVC sin pausa compensatoria	Un pulso en R3 seguido de otro en región normal.
<i>Couplet</i>	Dos pulsos consecutivos en R3 seguidos por otro en región normal o R5.
Braquicardia paroxística	Al menos 3 pulsos consecutivos en R5.
Taquicardia	Promediado de RR $< 120$ ppm: R1.
Fusión	Pulso con duración QRS grande; en R4.
<i>Escape</i>	Pulso con QRS retardado; en R5
Rechazado	Pulso con RR $< 200$ ms o duración QRS $< 60$ ms: R0.

Tabla 8.1. Tipos de patologías detectados por el sistema.

El centro de la región normal se actualiza continuamente, basándose en el promediado de los 8 pulsos más recientes clasificados como normales. Esta aproximación permite a la región normal moverse en el mapa siguiendo cambios normales del ritmo cardíaco que se producen durante el ejercicio o motivados por otros motivos fisiológicos. Los límites de las otras regiones se modifican también pulso a pulso, puesto que se basan en la localización de la región normal. Por tanto, el algoritmo se adapta a los cambios normales del ritmo.