

## **6. CAD propuesto para el PFC.**

### **6.1 Introducción.**

En el diseño del CAD que se propone en este proyecto tiene siempre como prioridad que cada uno de los algoritmos que usa emule el sistema de percepción humana.

Recordando la estructura general de un CAD, mencionado en el capítulo 3.3.2 (véase figura 3.5), el proceso general en el diagnóstico de las quemaduras constaba de cuatro partes.

En la segunda etapa (segmentación) es importante segmentar la parte de la quemadura correctamente, tal y como lo haría un especialista. Con este fin se implementa un algoritmo de segmentación basado en descriptores de color y textura (con el algoritmo LBP) [38]. Para eliminar las zonas segmentadas que se identifican como fondo o piel sana, se hace una primera clasificación con una red Fuzzy ARTMAP (véase capítulo 6.4.2.1) entrenada con recortes de fondo, piel sana y quemaduras, para procesar sólo las zonas de imagen correspondientes a piel quemada. Las características de clasificación para esta red son las medias de  $L^*$ ,  $a^*$ ,  $b^*$ .

En la siguiente etapa, la extracción de características, es crítico escoger unos parámetros que identifiquen unívocamente el grado de la quemadura. Para ello, se parte de los estudios que desarrollados con médicos expertos, [19], que arrojan una serie de características visuales que los especialistas usan para hacer la valoración de una lesión por quemadura.

En el último paso, en la clasificación, se elige una red neuronal [28], que lleva a cabo un procesado "parecido" al que hace el cerebro humano cuando un especialista intenta diagnosticar una quemadura.

A continuación se detallan cuales son los algoritmos y características que se evalúan en cada una de las etapas de nuestro algoritmo.

## **6.2 Algoritmo de segmentación**

### **6.2.1 Introducción.**

En la etapa de segmentación se implementa un algoritmo de segmentación de imágenes descrito en el artículo de Shiu-Ku Weng [13], el cual parte del artículo escrito por T. Ojala y M. Pietikäinen en 1999 [14], donde se describe un modelo de segmentación por división y fusión basado en histograma de textura, en el que las regiones se comparan por distancias estadísticas dadas por la función G estadística.

Weng propone la caracterización de la imagen a través de descriptores de color y textura, usando sendos histogramas como base para la comparación de regiones, ya que sustituye la función G de distancias estadísticas por la técnica de intersección de histogramas propuesta por Swain y Ballard en 1991 [15].

Esto fue implementado por Javier Cuadri en su PFC "*Segmentación de imágenes en color por intersección de histogramas de color y textura*" con directora de proyecto Irene Fondón.

### **6.2.2 Partes del algoritmo.**

Todo el procesado que se realiza se puede dividir en diferentes partes:



#### **6.2.2.1 Preparación de la imagen y cálculo de descriptores.**

En primer lugar, a la hora de la preparación de la imagen, se debe tener en cuenta las dimensiones de la imagen. Para el correcto

funcionamiento del algoritmo la imagen debe ser cuadrada y sus dimensiones potencia de dos.

Antes de realizar la segmentación, la imagen debe ser pre-tratada, calculando de esta forma los descriptores de color y textura con los que se trabaja en el proceso de segmentación.

### **6.2.2.1.1 Descriptor de color.**

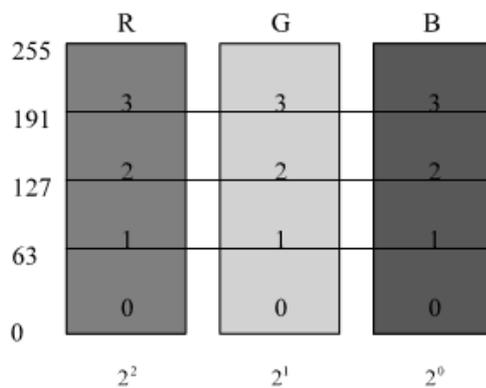
Cuando se realiza la adquisición de una imagen, ésta queda expresada por defecto según el modelo sRGB.

Una imagen RGB de tamaño  $N \times N$  es un conjunto de 3 matrices  $N \times N$ , cada una correspondiente a los colores R (Rojo), G (Verde) y B (Azul), de manera que un píxel queda representado por un vector de 3 valores [R, G, B], entre 0 y 255 (8 bits).

El tener un gran abanico de colores aporta mucha información de color, pero a su vez añade complejidad a la segmentación.

Para simplificar el proceso de segmentación, se propone una reducción significativa de información de color, sin que afecte a las características de color y textura de la imagen. Esta reducción de información se consigue con la transformación RGB a Índice de Color. Dicha transformación lleva a cuantificar el valor de cada píxel de la siguiente manera:

- Se dividen los 256 niveles RGB en L etiquetas, de manera que a cada valor RGB se le asigna la etiqueta del grupo al que pertenece en dicha división en L niveles. Así pues por ejemplo, para  $L=4$ , se divide de la siguiente forma:



**Fig. 6.1: Distribución de colores cuantizada en 4 niveles.**

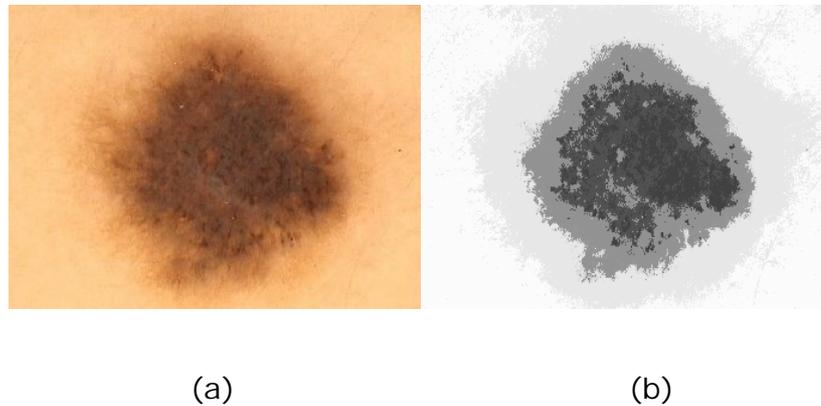
- El píxel con valor [255, 129, 10] se correspondería con la etiqueta [3, 2, 0].
- A continuación el vector etiquetas se convierte en índice, sumando los productos de las etiquetas del rojo por  $L^2$ , del verde por  $L^1$ , y del azul por  $L^0$ .

$$\begin{aligned} Tran_R &= R_{etiqueta} \times L^2 \\ Tran_G &= G_{etiqueta} \times L^1 \quad L = 2,4,8, \dots \\ Tran_B &= B_{etiqueta} \times L^0 \\ Tran_{RGB} &= Tran_R + Tran_G + Tran_B \end{aligned} \quad \text{(Ec. 6.1)}$$

- La etiqueta [3, 2, 0] daría un valor:

$$Tran_{RGB} = 3 * 16 + 2 * 4 + 0 * 1 = 56 \quad \text{(Ec. 6.2)}$$

- Así pues la imagen índice de color será una matriz de tamaño NxN que toma valores en el rango  $[0, L^3 - 1]$ . De manera visual la imagen cambia de color a escala de grises.



**Fig. 6.2: Imágenes que muestran su transformación a imágenes índice de color: a) Imagen RGB, b) Imagen índice de color.**

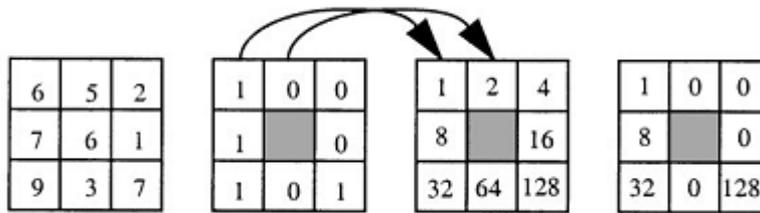
A partir de ahora se considera la matriz ICI como el descriptor de color de la imagen. Asociado al descriptor va el histograma índice de color CIH, que se utiliza como base para la segmentación y se define como:

$$CIH \quad hc_i = \frac{n}{p}, \quad i = 0, 1, 2, \dots, L^3 - 1 \quad \text{(Ec. 6.3)}$$

Donde  $n$  es el número de píxeles que toman el valor  $i$ ,  $P$  es el número total de píxeles de la imagen.

**6.2.2.1.2 Descriptor de textura.**

Como ya se ha comentado en la parte teórica, la textura viene definida por un método basado en histogramas, LBP, es decir, una medida de comparación vecinal de intensidades.



$$LBP = 1 + 8 + 32 + 128 = 169$$

La matriz LBP será pues, una matriz de tamaño  $N \times N$ , donde cada elemento es el patrón LBP del píxel correspondiente de la matriz imagen. Asociado al descriptor de textura, al igual que el de color, lleva el histograma de textura:

$$LBP \quad hb_i = \frac{n}{P}, \quad i = 0, 1, 2, \dots, L^3 - 1 \quad (Ec. 6.4)$$

donde  $n$  es el número de píxeles que toman el valor  $i$ ,  $P$  es el número total de píxeles de la imagen de texturas.



**Fig. 6.3: Ejemplo de descripción de texturas a) Imagen original, b) Imagen LBP de texturas.**

### 6.2.2.2 Segmentación de la quemadura.

Una vez calculados los descriptores de color y textura, se puede decir que la imagen está preparada para ser segmentada.

Como se ha visto el método de división y fusión, es una de las posibles formas de segregación de la imagen, que en este caso, es la que se va a utilizar. Fundamentalmente consta de 3 partes:

- División
- Fusión
- Mejora de los bordes

En cada una de las partes, el procedimiento es el de comparar regiones, ya sea para dividir las o unir las. Para realizar dicha comparación, hay que medir cuánto se parecen dos zonas de una imagen para decidir si se dividen o se fusionan. Es decir, sean dos partes de la imagen  $R$  y  $R'$ , usando los descriptores de color y textura anteriormente calculados, hay que hallar el descriptor combinado de comparación entre regiones  $H(R, R')$ , que se define como:

$$H(R, R') = W_{LBP} \times H_{LBP}(R, R') + W_{CIH} \times H_{CIH}(R, R') \quad (\text{Ec. 6.5})$$

Donde  $W_{LBP}$  y  $W_{CIH}$  son los pesos de color y textura del descriptor,  $H_{LBP}(R, R')$  y  $H_{CIH}(R, R')$  son las intersecciones de histogramas de color y textura. Todos estos elementos toman valores en el rango  $[0, 1]$ .

Se define la intersección de histogramas [15], como una medida de similitud de dos histogramas, correspondientes a dos regiones a comparar. Si el valor de la intersección se acerca a 1, los histogramas son semejantes y por tanto se puede decir que las regiones son similares. Si por el contrario el valor de la intersección se acerca a 0, o intersección nula, los histogramas no se parecen y por tanto son regiones diferentes.

Sean dos regiones  $R$  y  $R'$ , por un lado se calcula la intersección de los histogramas de color,  $H_{CIH}(R, R')$ , definido como:

$$H_{CIH}(R, R') = \sum_{i=0}^{L^3-1} \min(H_{C_i}, H_{C_i}') \quad (\text{Ec. 6.6})$$

y por otro lado la intersección de los histogramas de textura,  $H_{LBP}(R, R')$ , definido como:

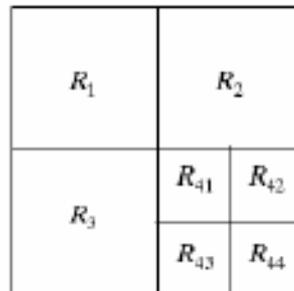
$$H_{LBP}(R, R') = \sum_{i=0}^{255} \min(Hb_i, Hb_i') \quad (\text{Ec. 6.7})$$

Se multiplica cada intersección por su peso correspondiente y se suman ambos valores, dando como resultado el descriptor combinado  $H(R, R')$ .

### 6.2.2.2.1 División de la imagen en regiones homogéneas.

La segmentación comienza con la creación de un árbol cuaternario de regiones.

Partiendo de la región imagen completa, se divide la región en 4 regiones de iguales dimensiones:  $R_1, R_2, R_3, R_4$ .



**Fig. 6.4: División en regiones.**

A continuación se calculan los descriptores combinados entre las 4 regiones:

$$H_{12}(R_1, R_2), H_{13}(R_1, R_3), H_{14}(R_1, R_4), H_{23}(R_2, R_3), H_{24}(R_2, R_4) \text{ y } H_{34}(R_3, R_4) \quad (\text{Ec. 6.8})$$

Se toman el máximo y con el mínimo de todos ellos y se comprueba si:

$$R = \frac{H_{max}}{H_{min}} > X \quad (\text{Ec. 6.9})$$

en cuyo caso significa que la región no es lo suficientemente homogénea y que hay que dividirla en los cuadrantes comprobados.

Seguidamente se comprueban cada una de las cuatro regiones resultantes de la división anterior, y así sucesivamente hasta que se compruebe toda la imagen, teniendo en cuenta que existe un tamaño mínimo de región de  $D_{mín}$  píxeles, tamaño a partir del cual ya no se puede aplicar la intersección de histogramas, debido al incremento del ruido.

Los parámetros  $D_{mín}$  y  $X$  son elegidos experimentalmente, de manera que se optimice la división de regiones, se ha elegido  $X = 1.05$  y  $D_{mín} = 8 \times 8$  píxeles, debido a que menores dimensiones presentan problemas importantes de ruido.

Una vez analizada toda la imagen, el resultado es un árbol cuaternario de regiones homogéneas.

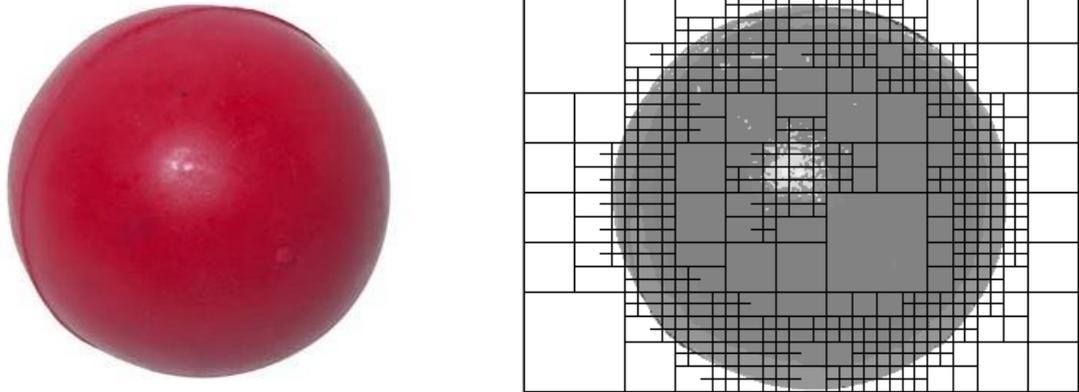


Fig. 6.5: Ejemplo de división de una imagen en regiones cuaternarias.

#### **6.2.2.2 Fusión de regiones homogéneas.**

Una vez calculado el árbol cuaternario, se dispone de un mapa de regiones homogéneas, el cual se recorre comparando cada región con sus adyacentes para ver si es posible una fusión debido a su parecido.

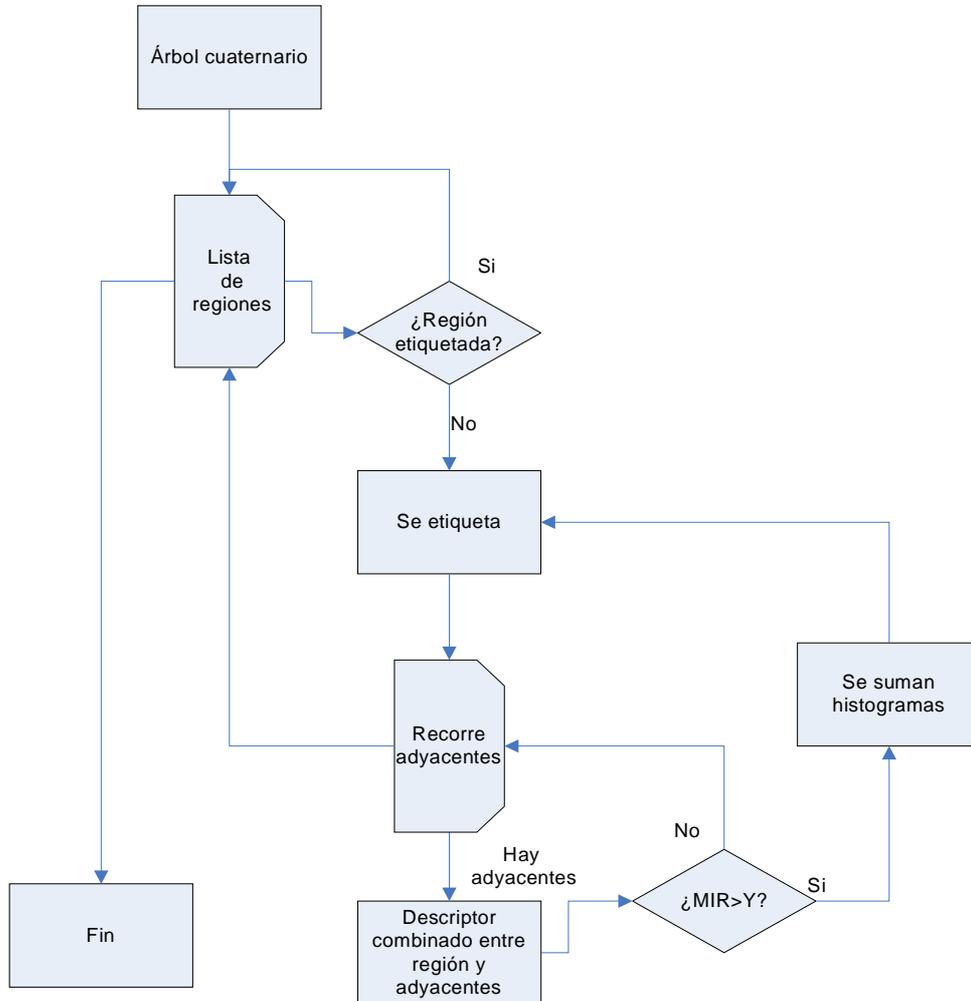
Así, partiendo de las regiones más pequeñas, se analiza cada región del árbol cuaternario, teniendo en cuenta las siguientes premisas:

- Cada región que se comprueba se etiqueta, siendo éste el identificativo para distinguirla del resto.
- Se crea un mapa de etiquetas donde se puede comprobar si una región ha sido comprobada o no en función de si está etiquetada o no.

Sabiendo esto, se describe el proceso que sigue una región para ver si se puede fusionar o no, de la siguiente forma:

1. Se recorre una por una todas las regiones del árbol cuaternario.
2. Se comprueba que la región no ha sido ya etiquetada y se le asigna una etiqueta.
3. Se crea un mapa con los segmentos adyacentes de la región que no estén etiquetados.

4. Se calculan los descriptores combinados de la región principal con sus adyacentes. Si cumplen el umbral de fusión  $MI > Y$ , se suman los histogramas y se etiqueta dicha región adyacente.
5. Una vez comprobadas todas las regiones adyacentes, en el caso de que haya habido fusión, se vuelve a calcular el mapa de regiones adyacentes y se vuelve al punto 3.
6. Una vez no haya más regiones que añadir, se vuelve al punto 1, pasando a otra región.



Todo el proceso de fusión va marcado de esta manera por el mismo descriptor combinado de comparación que se ha usado en la división de las regiones, con la intersección de histogramas como motor de la comparación.

Para poder entender el umbral de fusión se define la importancia de fusión  $MI$  como:

$$MI(R, R') = \frac{p}{H(R, R')} \quad (\text{Ec. 6.10})$$

Donde  $p$  es el número de píxeles de la región más pequeña de las que se compara y  $H(R, R')$  es el descriptor combinado de dichas regiones.

Así pues el umbral se define como:

$$MI > Y \quad (\text{Ec. 6.11})$$

De la misma manera que en la división, el umbral  $Y$  se ha tomado experimentalmente con el valor de  $Y = 0.42$

#### **6.2.2.2.3 Mejora de bordes.**

El proceso de división y fusión, ofrece un resultado algo basto en cuanto a tamaño mínimo de bloque, ya que deja bloques de 64 píxeles sin dividir, lo cual hace que los bordes sean imprecisos.

Como mejora se realiza un realzado de bordes, por medio de una clasificación de los píxeles contiguos. El proceso es el siguiente:

1. Se calcula una imagen de bordes a partir de la imagen de etiquetas que ofrece como resultado la fusión de regiones.
2. Los píxeles frontera se toman como centro de un círculo de radio 11, calculando los histogramas de color y textura de dicha región circular.
3. Se realiza una comparación por medio del descriptor combinado  $H(R, R')$  entre la región circular y las regiones que forman dichas fronteras. Aquella región que aporte el mayor descriptor combinado, será la que se anexe dicho píxel frontera.
4. Este proceso recorre todos los píxeles frontera al menos 3 veces.

Toda esta mejora de bordes consigue que las fronteras sean algo menos rudas, usando técnicas de intersección de color y texturas también para mejorar dichas regiones.

#### **6.2.2.3 Elección de los parámetros.**

La elección de los parámetros ha sido realizada de manera experimental, a través de las diferentes pruebas hasta optimizar la segmentación. Por ello el algoritmo cuenta con varios parámetros que son:

- $L$ , factor de conversión de RGB a índice de color ICI, se toma  $L=4$ .
- $X$ , parámetro que marca la división en regiones, que se ha tomado el valor  $X=1.05$ . Es un valor que permite dividir la imagen en muchas regiones, confiando en la fusión como motor principal de la segmentación.

- $D_{min}$ , marca la dimensión más pequeña que se puede dividir una región. Se ha elegido  $D_{min} = 8$  o lo que es lo mismo  $Dim=8 \times 8=64$  píxeles.
- $Y$ , que marca la fusión de regiones como umbral del parámetro de máxima importancia de la región. Se ha tomado  $Y = 0.42$ .

La imagen que se obtiene del algoritmo de segmentación es la que se observa en la figura 6.6 (b). Para seleccionar sólo las zonas de la imagen que se identifican como quemaduras se clasifica la imagen original con una red neuronal Fuzzy ARTMAP (la cual se explica detalladamente en el capítulo 6.4.2.1), entrenada con imágenes representativas de fondo de imagen, de piel sana y de quemaduras. Combinando la información de la salida del algoritmo de segmentación y de la red neuronal obtenemos la imagen 6.6 (d) que será la que se procesará en las siguientes etapas del CAD.

El uso de esta primera red neuronal está justificado, pues la eliminación de las zonas no afectadas por la quemadura disminuye considerablemente el coste computacional del algoritmo, debido a que los parámetros de entrada de la segunda red conllevan unos cálculos más costosos.

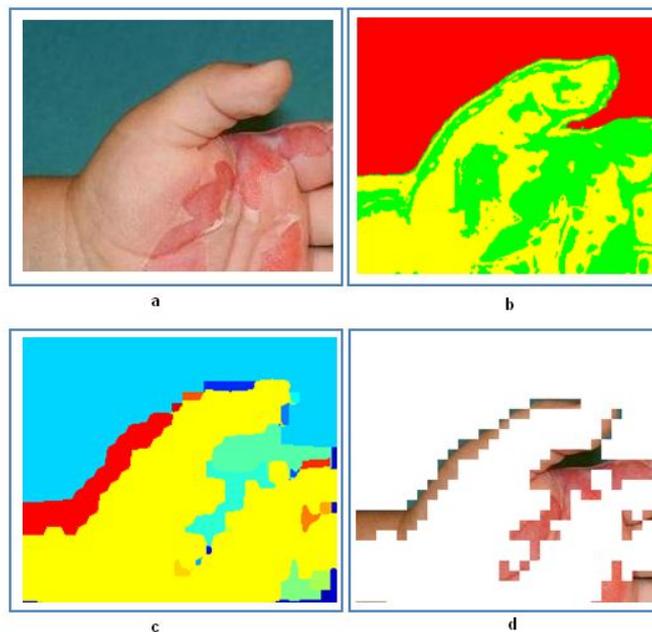


Fig. 6.6: (a) Imagen original, (b) clasificación de la red en espacio  $L^*a^*b^*$ , (c) imagen completa segmentada, (d) quemadura segmentada y aislada.

## **6.3 Algoritmo de extracción de características.**

### **6.3.1 Introducción.**

Este apartado se centra en la extracción de los parámetros que emplea la red neuronal para clasificar las quemaduras.

Es complicado elegir un conjunto de características que consigan definir de forma clara a qué grado de quemadura pertenece cada uno de los píxeles de la imagen a clasificar.

La elección de estos parámetros se basa en el estudio de [19], en el que se lleva a cabo un análisis que trata de condensar las características en las que se basan los médicos a la hora de diagnosticar las quemaduras que son comunes de cada uno de los grados, en tres parámetros que serán las entradas a la red neuronal.

### **6.3.2 Extracción de parámetros.**

Como ya se ha comentado, la red neuronal recibe 3 parámetros para clasificar las quemaduras.

Cada píxel de la imagen a clasificar posee un vector con tres componentes, que ha de identificar inequívocamente el grado al que pertenece dicho píxel. Por lo tanto, la red tiene como entrada un vector de 3 columnas y tantas filas como píxeles contenga la imagen.

Tanto para el parámetro d1 como para d3 se recorre la imagen, seleccionando alrededor de cada píxel una ventana de tamaño 3x3 píxeles. Se calculan los ambos parámetros mediante las formulas que se exponen en los capítulos 6.3.2.1 y 6.3.2.3, asignando al píxel central de la ventana los valores calculados.

El parámetro d2 se calcula sobre la imagen completa. Este parámetro identifica el número de centroides de la quemadura completa. En este estudio se comparan los resultados de dos métodos distintos. En el primero se calcula el número de centroides utilizando la distancia Euclídea, mientras que en el segundo caso se hace uso de la novedosa distancia CIEDE2000.

**6.3.2.1 Extracción de d1.**

El cálculo de este parámetro se basa en el estudio de [19]. Esta característica está relacionada con la cantidad de color rosa que posee la imagen. En d1 se hace un ajuste de cuarto orden, usando como parámetros la media de H y de S. en la tabla 6.1 se puede ver que el coeficiente de ajuste para las características elegidas es realmente alto, por lo que los resultados de la clasificación han de ser satisfactorios.

<b>Análisis No Lineal de 4° orden</b>			
<b>Coeficiente de ajuste</b>	<b>Coordenada (H)</b>	<b>Coordenada (S)</b>	<b>Coordenada (H,S)</b>
R <sup>2</sup>	0.491	0.384	0.907

**Tabla 6.1. Resultados del análisis no lineal de 4° orden.**

La ecuación de ajuste para el parámetro d1 sería:

$$Y = pr_1 + pr_2 X_1 + pr_3 X_2 + pr_4 X_1^2 + pr_5 X_2^2 + pr_6 X_1^3 + pr_7 X_2^3 + pr_8 X_1^4 + pr_9 X_2^4 \quad (\text{Ec. 6.12})$$

Los valores de ponderación pr<sub>x</sub> resultantes son los siguientes:

<b>Valores de los parámetros del análisis no lineal de 4° orden</b>		
	<b>Valor</b>	<b>Desviación típica</b>
pr <sub>1</sub>	3,97313812343573	1,42243648847397
pr <sub>2</sub>	-0,48208753521423	0,21094323685295
pr <sub>3</sub>	-0,01574751530487	0,01699500330135
pr <sub>4</sub>	0,01757580519742	0,01027114239929
pr <sub>5</sub>	0,00253125475316	0,00074436938534
pr <sub>6</sub>	-0,00026746103565	0,00020272371045
pr <sub>7</sub>	-0,00003697365034	0,00000951481083
pr <sub>8</sub>	0,00000142357847	0,00000138947091
pr <sub>9</sub>	0,00000013210320	0,00000003332753

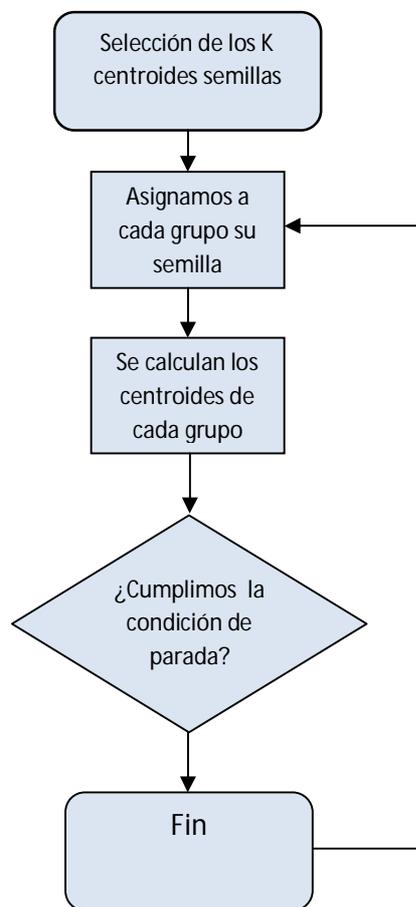
**Tabla 6.2. Parámetros resultantes del análisis no lineal de 4° orden.**

Se observa que a partir del parámetro pr<sub>5</sub> los valores son muy pequeños y eliminarlos no supone un error significativo.

### 6.3.2.2 Extracción del parámetro d2.

Este parámetro calcula el número de centros de color que contiene la imagen, esto está relacionado con la textura de la superficie de la quemadura. En este caso el método usado será el de k-medias. Este tipo de método es conveniente utilizarlo cuando los datos a clasificar son muchos y/o para refinar una clasificación obtenida utilizando un método jerárquico. Supone que el número de grupos es conocido a priori.

Existen varias formas de implementarlo pero todas ellas siguen, básicamente, los siguientes pasos:



**Fig. 6.7: Algoritmo de k-means.**

1. Se seleccionan k centroides o semillas donde k es el número de grupos deseado.
2. Se asigna cada observación al grupo cuya semilla es la más cercana.
3. Se calculan los puntos semillas o centroides de cada grupo.

4. Se iteran los pasos 2) y 3) hasta que se satisfaga un criterio de parada como, por ejemplo, los puntos semillas apenas cambian o los grupos obtenidos en dos iteraciones consecutivas son los mismos.

#### **6.3.2.2.1 Con distancia euclídea.**

En este apartado se empleara en el algoritmo de k-means la distancia euclídea clásica.

#### **6.3.2.2.2 Con distancia CIEDE2000.**

En el cálculo del número de centroides, se cambia la distancia euclídea por la CIEDE2000, descrita en el apartado 4.3. Este algoritmo se hace mucho más lento, debido al peso matemático del mismo.

Para conseguir que el algoritmo k-means converja en un tiempo aceptable, se introduce una modificación respecto al empleado en la primera opción. Primero hemos de ejecutar k-means con distancia euclídea, y pasarle los centroides obtenidos como resultado, para que el nuevo algoritmo los use como semillas de inicio.

#### **6.3.2.3 Extracción del parámetro d3.**

La característica d3 tiene que identifica el grado de frescura de la zona de piel quemada. El cálculo del parámetro d3 se lleva a cabo de una forma muy similar a d1. En este caso se consideraron un gran número de características, hasta que se definió el conjunto que más se ajustaba al modelo deseado. Algunas de las características seleccionadas para el cálculo de d3 son:

- Media de B (Color azul del sistema RGB).
- Media de la Luminosidad.
- Media de V (Valor o brillo del sistema HSV).

- Media de  $v^*$  (Sistema  $Lu^*v^*$ ).
- Desviación típica de B.
- Desviación típica de la Luminosidad.
- Desviación típica de V.
- Desviación típica de  $v^*$ .
- Torsión de V.
- Torsión de B.
- Torsión de  $v^*$ .
- Curtosis de V.
- Desviación típica de B.

Una explicación más extensa de las características, así como de los distintos sistemas de representación de imágenes en color puede obtenerse en [16].

El análisis llevado a cabo demostró que el mejor ajuste se obtenía con el siguiente subconjunto:

- Media de B
- Media de la luminosidad.
- Media de V.
- Torsión de V.

Los resultados para este ajuste fueron los siguientes:

<b>Análisis no lineales.</b>			
<b>Coefficiente de ajuste</b>	<b>2º orden</b>	<b>3<sup>er</sup> orden</b>	<b>4º orden</b>
R <sup>2</sup>	0.695	0.866	0.994

**Tabla 6.3. Resultado de análisis no lineales para d3.**

Por último, la ecuación de ajuste correspondiente sería:

$$Y = pr_1 + pr_2 X_1 + pr_3 X_2 + pr_4 X_3 + pr_5 X_4 + pr_6 X_1^2 + pr_7 X_2^2 + pr_8 X_3^2 + pr_9 X_4^2 + pr_{10} X_1^3 + pr_{11} X_2^3 + pr_{12} X_3^3 + pr_{13} X_4^3 + pr_{14} X_1^4 + pr_{15} X_2^4 + pr_{16} X_3^4 + pr_{17} X_4^4 \quad (\text{Ec. 6.13})$$

Donde los parámetros toman los siguientes valores:

<b>Valores de los parámetros del análisis no lineal de 4º orden</b>		
<b>Parámetros</b>	<b>Media</b>	<b>Desviación típica</b>
pr <sub>1</sub>	-475,092697605148	99,889234499882
pr <sub>2</sub>	0,306751859739	0,122491705340
pr <sub>3</sub>	1,091641841190	0,098504762019
pr <sub>4</sub>	25,855695546476	4,668007509568
pr <sub>5</sub>	-23,384325007518	3,803193875090
pr <sub>6</sub>	-0,003016988627	0,001613365414
pr <sub>7</sub>	-1,016754280093	0,237802834153
pr <sub>8</sub>	-0,303819924327	0,054997165291
pr <sub>9</sub>	0,573629958926	0,095050188705
pr <sub>10</sub>	0,000024294986	0,000011012779
pr <sub>11</sub>	-1,988560579689	0,212376243034
pr <sub>12</sub>	0,001553250147	0,000282861195
pr <sub>13</sub>	-0,006060586915	0,001033895718
pr <sub>14</sub>	-0,000000076021	0,000000028521
pr <sub>15</sub>	-0,049322983974	0,259181541129
pr <sub>16</sub>	-0,000002941336	0,000000539784
pr <sub>17</sub>	0,000023549007	0,000004166338

**Tabla 6.4: Parámetros resultantes del análisis no lineal de 4º orden.**

Una vez obtenidas las características mencionadas, se aplican como entrada a la red neuronal, para que clasifique cada una de las quemaduras.

## 6.4 Algoritmo de clasificación.

### 6.4.1 Introducción a las redes neuronales.

Las redes de neuronas artificiales (denominadas habitualmente como RNA o en inglés como: "ANN") son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida.

Las redes neuronales consisten en una simulación de las propiedades observadas en los sistemas neuronales biológicos a través de modelos matemáticos recreados mediante mecanismos artificiales. El objetivo es conseguir que las máquinas den respuestas similares a las que es capaz de dar el cerebro que se caracterizan por su generalización y su robustez.

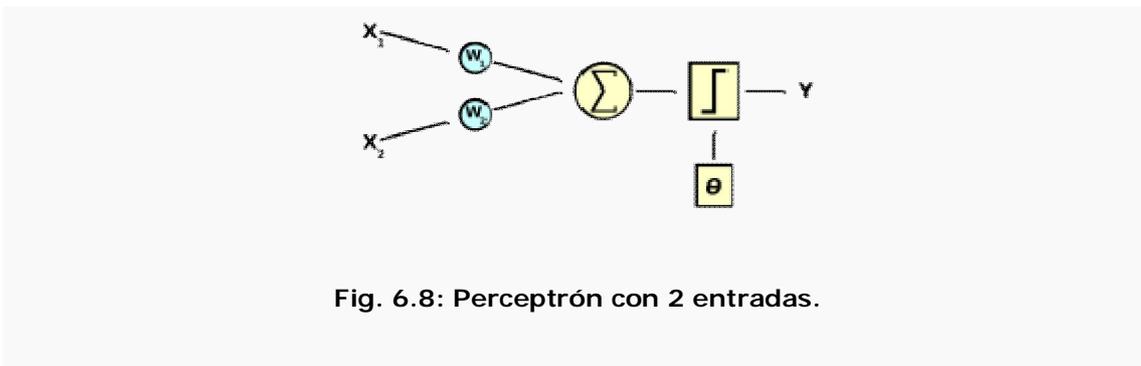


Fig. 6.8: Perceptrón con 2 entradas.

Una red neuronal se compone de unidades llamadas neuronas. Cada neurona recibe una serie de entradas a través de interconexiones y emite una salida [17]. Esta salida viene dada por tres funciones:

1. Una función de propagación (también conocida como función de excitación), que por lo general consiste en el sumatorio de cada entrada multiplicada por el peso de su interconexión. Si el peso es positivo, la conexión se denomina excitatoria; si es negativo, se denomina inhibitoria.
2. Una función de activación que modifica a la anterior. Puede no existir, siendo en este caso la salida la misma función de propagación.
3. Una función de transferencia que se aplica al valor devuelto por la función de activación. Se utiliza para acotar la salida de la neurona y

generalmente viene dada por la interpretación que queramos darle a dichas salidas.

#### **6.4.1.1 Topología de una red neuronal.**

Una primera clasificación de las redes de neuronas artificiales que se suele hacer es en función del patrón de conexiones que presenta. Así se definen tres tipos básicos de redes:

- Dos tipos de redes de propagación hacia delante o acíclicas en las que todas las señales van desde la capa de entrada hacia la salida sin existir ciclos, ni conexiones entre neuronas de la misma capa.
  - Monocapa. Ejemplos: Perceptrón, Adaline.
  - Multicapa. Ejemplos: Perceptrón multicapa.
- Las redes recurrentes que presentan al menos un ciclo cerrado de activación neuronal.

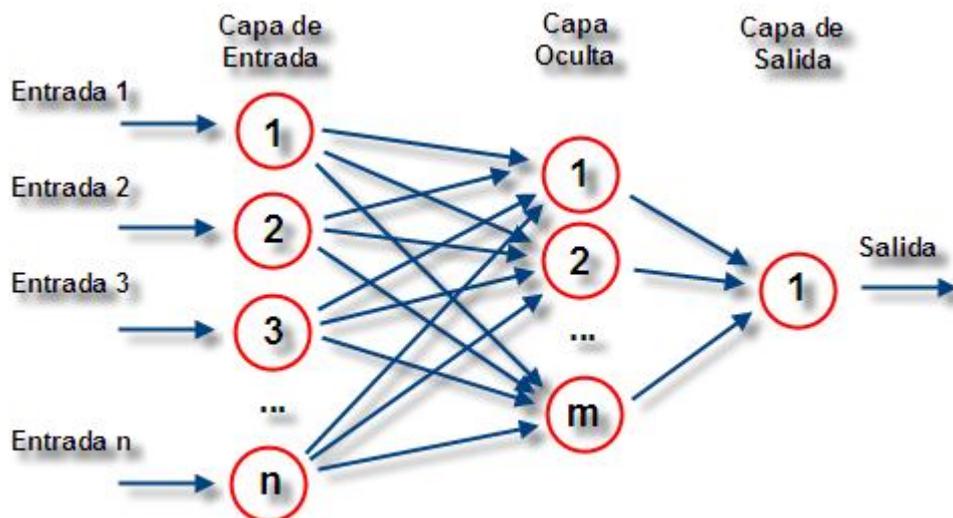


Fig. 6.9: Estructura de una red neuronal.

#### **6.4.1.2 Aprendizaje de la red neuronal.**

Una segunda clasificación que se suele hacer es en función del tipo de aprendizaje de que es capaz (si necesita o no un conjunto de entrenamiento supervisado). Para cada tipo de aprendizaje encontramos varios modelos propuestos por diferentes autores:

- Aprendizaje supervisado: necesitan un conjunto de datos de entrada previamente clasificado o cuya respuesta objetivo se conoce. Ejemplos de este tipo de redes son: el Perceptrón simple, la red Adaline, el Perceptrón multicapa, red backpropagation, y la memoria asociativa bidireccional.
- Aprendizaje no supervisado o auto organizado: no necesitan de tal conjunto previo. Ejemplos de este tipo de redes son: las memorias asociativas, las redes de Hopfield, la máquina de Boltzmann y la máquina de Cauchy, las redes de aprendizaje competitivo, las redes de Kohonen o mapas auto organizados y las redes de resonancia adaptativa (ART).
- Redes híbridas: son un enfoque mixto en el que se utiliza una función de mejora para facilitar la convergencia. Un ejemplo de este último tipo son las redes de base radial.
- Aprendizaje reforzado: se sitúa a medio camino entre el supervisado y el autoorganizado.

#### **6.4.1.3 Tipo de entrada en las redes neuronales.**

Finalmente también se pueden clasificar las RNAs según sean capaces de procesar información de distinto tipo en:

- Redes analógicas: procesan datos de entrada con valores continuos y, habitualmente, acotados. Ejemplos de este tipo de redes son: Hopfield, Kohonen y las redes de aprendizaje competitivo.
- Redes discretas: procesan datos de entrada de naturaleza discreta; habitualmente valores lógicos booleanos. Ejemplos de este segundo tipo de redes son: las máquinas de Boltzmann y Cauchy, y la red discreta de Hopfield.

#### **6.4.1.4. Ventajas de las redes neuronales.**

Las redes neuronales artificiales (RNA) tienen muchas ventajas debido a que están basadas en la estructura del sistema nervioso, principalmente el cerebro.

- Aprendizaje: Las RNA tienen la habilidad de aprender mediante una etapa que se llama etapa de aprendizaje. Esta consiste en proporcionar a la RNA datos como entrada a su vez que se le indica cuál es la salida (respuesta) esperada.
- Auto organización: Una RNA crea su propia representación de la información en su interior, descargando al usuario de esto.
- Tolerancia a fallos: Debido a que una RNA almacena la información de forma redundante, ésta puede seguir respondiendo de manera aceptable aun si se daña parcialmente.
- Flexibilidad: Una RNA puede manejar cambios no importantes en la información de entrada, como señales con ruido u otros cambios en la entrada (por ejemplo si la información de entrada es la imagen de un objeto, la respuesta correspondiente no sufre cambios si la imagen cambia un poco su brillo o el objeto cambia ligeramente).
- Tiempo real: La estructura de una RNA es paralela, por lo cual si esto es implementado con computadoras o en dispositivos electrónicos especiales se pueden obtener respuestas en tiempo real.

#### **6.4.2 Red Fuzzy ARTMAP.**

Como clasificador de este proyecto se utiliza una red neuronal Fuzzy-ARTMAP. Este tipo de red se basa en la Teoría de Resonancia Adaptativa desarrollados por Grossberg y Carpenter [18].

La red ART tiene la habilidad de crear nuevas categorías con una aproximación arbitraria para clasificar entradas que no son clasificadas en las categorías existentes. Con la introducción de conceptos difusos, la Fuzzy ARTMAP [18] fue desarrollada por Carpenter y Grossberg en 1994. El término MAP se refiere al proceso de mapear las entradas a la salida. Esta red es una síntesis de la ART-1 [16] y la lógica difusa y es capaz de aceptar entradas continuas o binarias.

**6.4.2.1 Arquitectura de la red Fuzzy ARTMAP.**

La Fuzzy ARTMAP es una arquitectura autoorganizativa que es capaz de aprender a reconocer rápidamente, y predecir las consecuencias de virtualmente cualquier entrada. La ARTMAP involucra una combinación de operaciones neuronales y difusas, que juntas producen estas capacidades de la red. Como otras versiones de la ART, su uso es casi exclusivamente para clasificación, y solo tiene un parámetro de interfaz, el parámetro de vigilancia, el cual determina la fineza o generalidad de las categorías en las cuales las entradas son clasificadas. La red puede aprender virtualmente cualquier patrón de entrenamiento en pocas iteraciones de entrenamiento en un modo no supervisado.

Kasuba desarrolló una fuzzy ARTMAP simplificada en 1993. Esta red reduce la sobrecarga computacional y la redundancia de la arquitectura de una red ARTMAP sin perder la capacidad de reconocimiento de patrones.

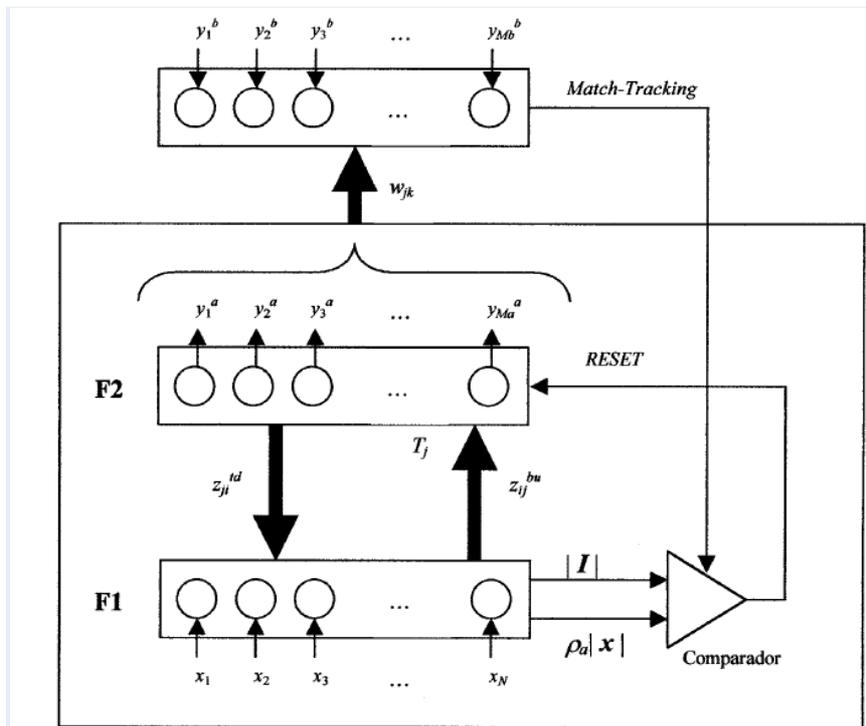


Fig. 6.10: Arquitectura de ARTMAP simple [16].

Cada neurona de F1 representa una característica o parámetro del patrón de entrada, mientras que cada una de las neuronas de la fila F2 representa una posible categoría en la que se puede clasificar los patrones de entrada.

Por tanto existen tantas características como  $y_j$  tenga la red y tantos tipos de patrones como  $x_j$ .

Cada una de las neuronas de la capa F1 está conectada con las neuronas de la capa F2 a través de un peso  $w_{ij}^{BU}$ , que toma un valor entre 0 y 1. En el sentido contrario de forma análoga se relacionan las neuronas de la fila F2 con las de la capa F1 mediante los pesos denotados como  $w_{ij}^{TD}$ .

Por tratarse de un modelo Fuzzy-ART los pesos de conexión de abajo a arriba son iguales que en el sentido contrario, esto es:

$$z_{ij} = z_{ij}^{bu} = z_{ij}^{td} \quad (\text{Ec. 6.14})$$

La entrada a una neurona j de la capa F2 viene dada por la expresión:

$$T_j = \sum_{i=1}^N z_{ij}^{bu} x_i \quad j=1, 2 \dots M. \quad (\text{Ec. 6.15})$$

Los términos  $T_j$  se denominan función de elección, y representa la diferencia entre el patrón almacenado y el de entrada.

Todas las neuronas de la capa F2 pondrán su salida a 0, excepto la que recibe un valor de  $T_j$  mayor, que pondrá su salida a 1.

La entrada a una neurona de la capa F1 será:

$$V_j = \sum_{i=1}^M z_{ij}^{td} y_j \quad i=1, 2 \dots N \quad (\text{Ec. 6.16})$$

La configuración ARTMAP posee un módulo Map-Field, tal y como aparece en la figura 6.11. El vector  $y_b$  es tal que todas sus componentes son 0, excepto la de la clase a la que pertenece, que estará a uno. De esta forma le decimos a la red a qué categoría pertenece el patrón.

Cabe mencionar también el uso de la codificación complementaria. Es útil que la norma de los patrones de entrada  $x$  sea la misma para todos. Para redes ART con entrada analógica (Fuzzy-ART y Fuzzy-ARTMAP) esto evita la proliferación de clases o categorías [18]. La codificación de complemento es un proceso de normalización de la entrada que representa la presencia o ausencia de un vector característico particular a con  $d$  componentes en la entrada. Su complemento  $\hat{a} = 1 - a$  es válido dado que  $a$  es un valor entre 0 y 1. Por lo tanto, el complemento del vector de entrada  $I$  esta dado por el vector bidimensional:

$$I = [a, \hat{a}] = [a_1, a_2, \dots, a_d, \hat{a}_1, \hat{a}_2, \dots, \hat{a}_d] \quad (\text{Ec. 6.17})$$

Por ejemplo, el vector tridimensional (0.2,0.8,0.4) se transforma en un vector de seis dimensiones (0.2,0.8,0.4,0.8,0.2,0.6) cuando pasa a través del codificador de complemento. Este proceso automáticamente normaliza los vectores de entrada indicando que la norma de cualquier vector es la suma de todos los elementos del vector. Es decir, la suma de los elementos de un vector complemento es igual a la dimensión del vector original.

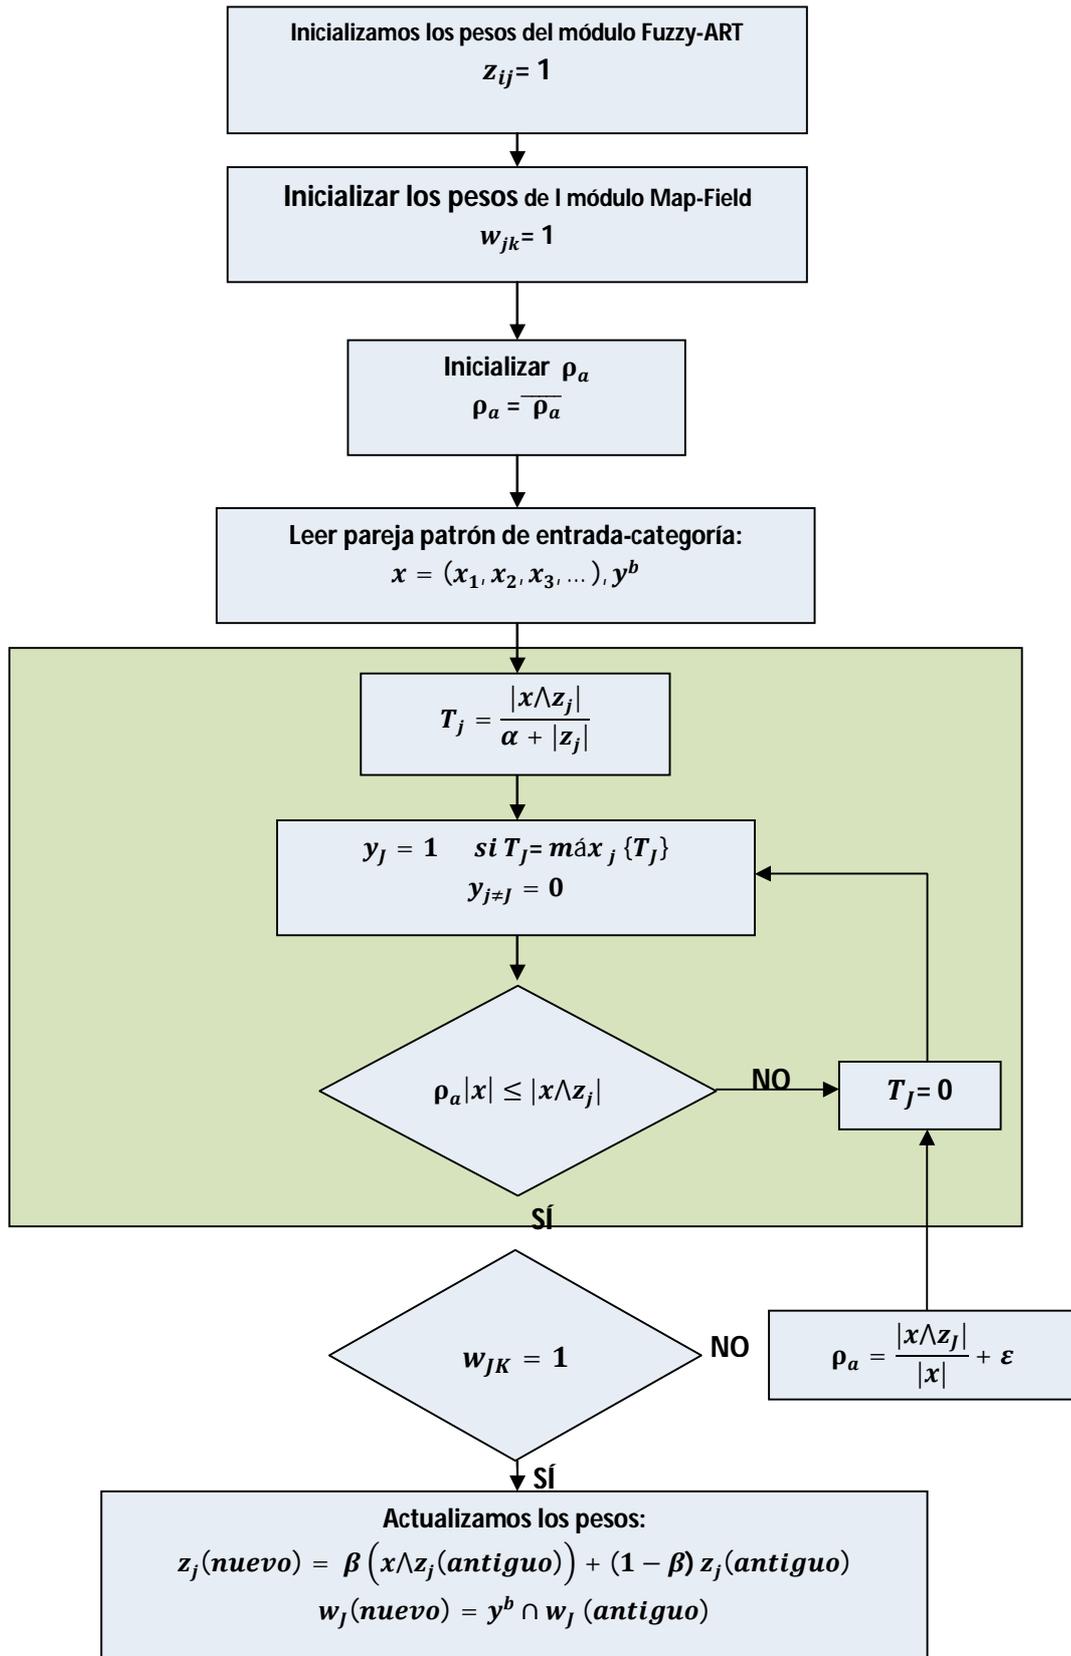


Fig. 6.11: Diagrama de flujo de una arquitectura Fuzzy ARTMAP [16].

Las razones de la elección de la red Fuzzy-ARTMAP es que ofrece las ventajas propias de las redes neuronales, una convergencia muy rápida, admite entradas analógicas y tiene un entrenamiento supervisado. También hay que mencionar que este tipo de redes tienen un historial de uso exitoso en aplicaciones industriales y médicas.

Otro punto fuerte de este tipo de redes neuronales son el reducido número de parámetros de diseño (el parámetro de vigilancia, y el parámetro de selección).

### **6.4.3 Entrenamiento de la red.**

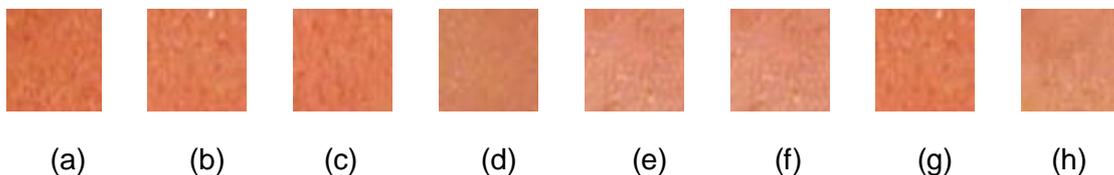
Para el entrenamiento de la red, se emplea un conjunto de recortes de quemaduras de cada uno de los grupos a identificar de tamaño 49x49 píxeles [19].

La elección de las imágenes de entrenamiento se basa en las características que se han mencionado en el capítulo 1. Aunque hay que tener en cuenta que siempre habrá un punto de subjetividad en la elección de las mismas.

La red se entrena con un total de:

- 25 entradas para 2º grado superficial
- 20 entradas para 2º grado profundo
- 25 entradas para tercer grado
- 1 entrada para fondo de imagen

A continuación se muestran algunos de los recortes usados en la precarga de la red:



**Fig. 6.12: Recortes elegidos para entrenar a la red en segundo grado superficial.**

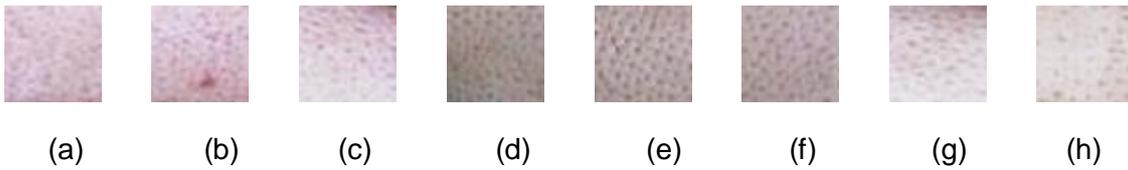


Fig. 6.13: Recortes elegidos para entrenar a la red en segundo grado profundo.

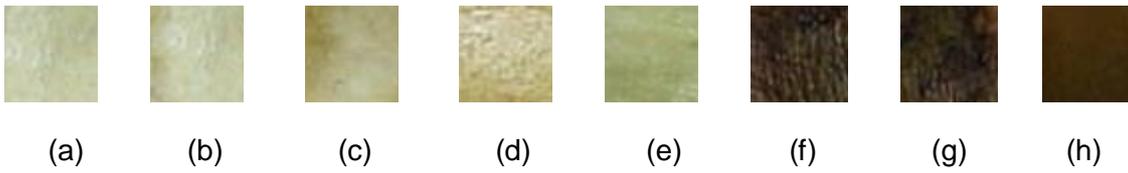


Fig. 6.14: Recortes elegidos para entrenar a la red en tercer grado

#### **6.4.4 Clasificación escogida.**

La red discrimina 4 casos posibles a la salida:

- Quemadura de segundo grado superficial
- Quemadura de segundo grado profundo
- Quemadura de tercer grado
- Fondo de imagen

Con lo cual, la red cuenta con seis neuronas en la capa de entrada y cuatro neuronas en la capa de salida.

6.5 Resumen del CAD.

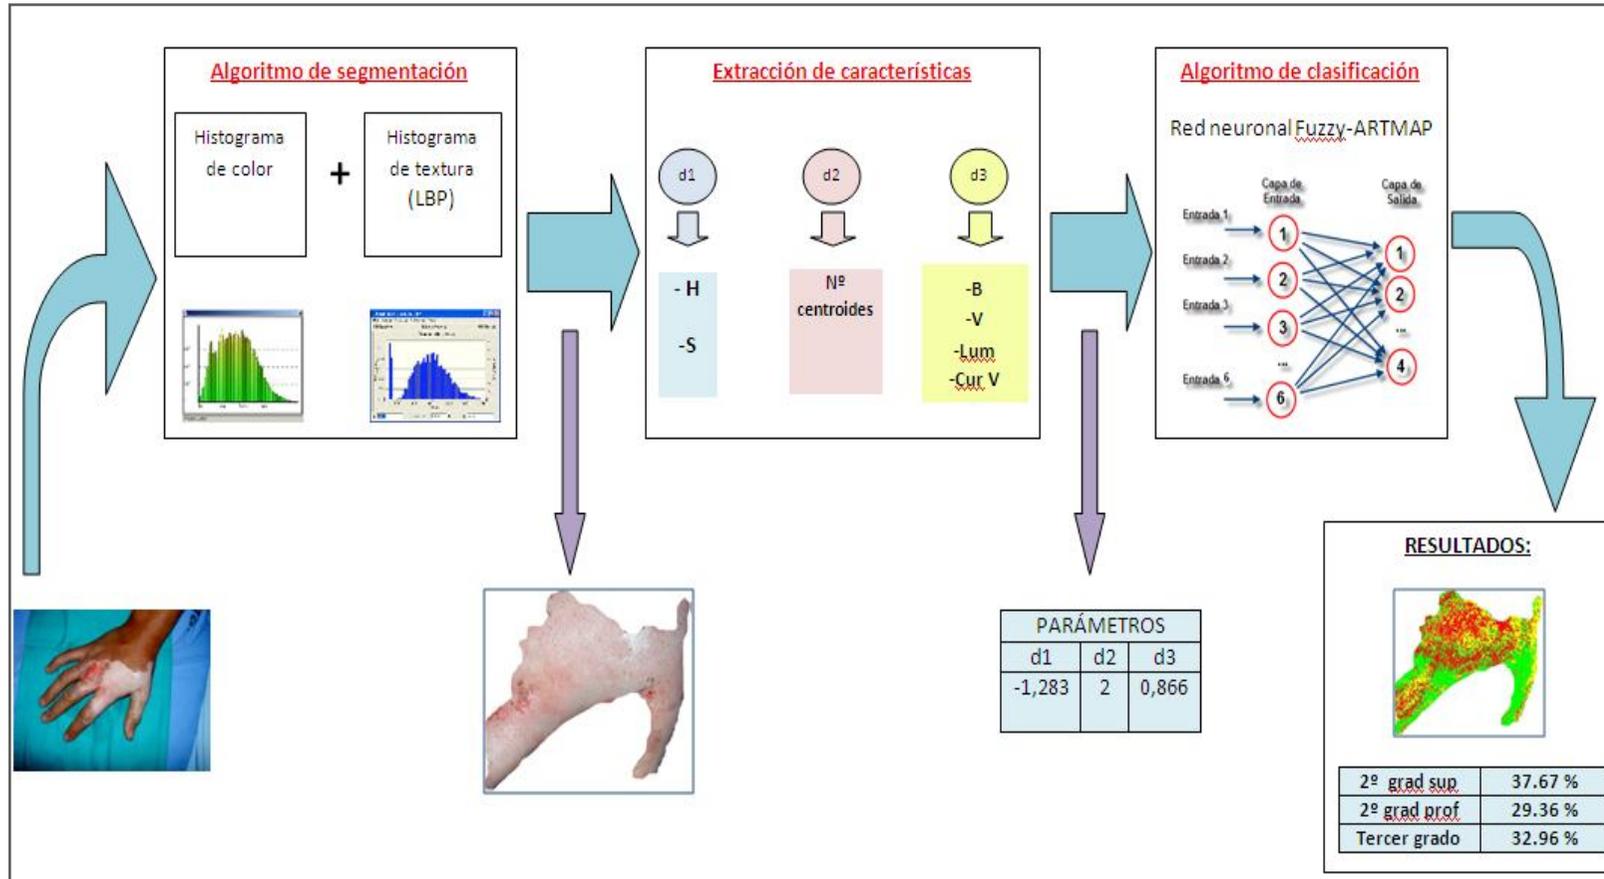


Fig. 6.15: Figura resumen del CAD.

