

ÍNDICE

	Pág.
1. Introducción	3
2. Textura	5
2.1. Concepto de textura	5
2.2. Imágenes a color	6
2.3. Descriptores de textura	9
2.3.1. Histograma.....	10
a. Blanco y Negro	13
b. Color.....	13
2.3.2. Matriz de Co-ocurrencia	13
- Introducción.....	13
- Concepto de Matriz de Co-ocurrencia	14
- Cálculo de la Matriz de Co-ocurrencia	17
- Relación espacial entre dos píxeles	18
- Distancia entre píxeles	18
- Normalización de la matriz	19
- Propiedades de la matriz	22
- Medidas de textura	23
2.3.3. Simplified Texture Unit (STU)	27
a. Texture Unit (TU)	27
- Introducción a la TU	27
- Metodología	28
- Ventajas de la TU sobre otros métodos estadísticos.....	31
b. Mejoras de la TU: STU	32
- Introducción a la STU	32
- Descriptores de textura local: de la TU a la STU	34
- Experimentos y resultados de M. Prieto	36
- Conclusiones de M. Prieto sobre la STU	38

2.4. Distancias	39
2.4.1. L2 sobre estadísticos	40
2.4.2. Comparación de distribuciones	40
a. Función Chi-cuadrado	41
b. Diferencia de histogramas L1	41
c. Distancia cuadrática L2	42
d. Intersección de histogramas.....	42
3. Software para la comparación de algoritmos.....	43
3.1. Funcionamiento del programa.....	43
3.2. Obtención de la base de datos	58
4. Estudio Comparativo.....	71
4.1. Obtención de las imágenes de humo	71
4.2. Estudio comparativo de los distintos métodos según sus características.....	72
- Estudio de los parámetros de Histograma en blanco y negro	78
- Estudio de los parámetros de Co-ocurrencia en blanco y negro	90
- Estudio de los parámetros de Co-ocurrencia en color	95
- Estudio de los parámetros de STU	98
4.3. Estudio comparativo entre los distintos métodos	101
- Algoritmo KNN (k-nearest neighbor algorithm)	102
- Tasa de Error Cruzado (Misclassification Rate, MCR).....	104
4.3.1. Resultados del estudio con la primera base de datos.....	105
4.3.2. Resultados del estudio con la base de datos ampliada	111
5. Conclusiones.....	115
5.1. Importancia de la buena elección de la base de datos de muestras.....	115
5.2. Eficacia de los distintos métodos	116
5.3. Mejoras	117
6. Bibliografía.....	119

1. Introducción

En numerosas ocasiones se ha intentado abordar el tema de la prevención de incendios forestales mediante múltiples métodos y sistemas de prevención. En el año 2000 se inició un proyecto donde colabora la Universidad de Sevilla, llamado proyecto INFLAME que se ha dedicado a la investigación en incendios forestales incluyendo métodos de adquisición de información, modelado, y soporte a la extinción. Se ha puesto énfasis en la depuración de los métodos desarrollados así como en la experimentación y validación de los resultados obtenidos en años anteriores empleando mapas del terreno para mejorar la precisión de las medidas. Se ha investigado en métodos de segmentación de imágenes de columnas de humo con vistas a su localización, en técnicas de umbralización automática de imágenes de infrarrojo, así como en el filtrado de los resultados del análisis de secuencias de imágenes para eliminar el efecto de vibraciones y otras perturbaciones en la toma de medidas. Se ha mejorado también la herramienta informática que permite aplicar en tiempo real las técnicas mencionadas.

Asimismo, se han realizado nuevos experimentos, participando en las quemas controladas realizadas en Mayo de 2001 en Gestosa, cerca de Coimbra (Portugal), utilizando simultáneamente diversas cámaras, visuales y en el infrarrojo, situadas en tierra y en helicópteros dotados de GPS. Se obtienen medidas de la altura de las llamas, avance del frente, anchura del frente y velocidad de propagación, en tiempo real, aplicando técnicas de visión por computador, georreferenciación y fusión sensorial.

Entre otros métodos se han realizado métodos de detección de columnas de humo a través de algoritmos de seguimiento y detectores de movimiento, así como algoritmos basados en descriptores de color, etc.

Este proyecto va a tratar de realizar un estudio de distintos métodos basados en el reconocimiento de patrones de textura. Hasta ahora, la segmentación de imágenes de humo basada en reconocimiento de muestras de textura no se había llevado a cabo. Entre otros motivos por la complicación que lleva detectar la textura del humo, dada su variabilidad.

Se van a proponer distintos métodos basados en métodos estadísticos de primer y de segundo orden como los métodos del Histograma y de la Matriz de Co-ocurrencia, así como métodos recientemente propuestos como el método de la Unidad Simplificada de Textura (*Simplified Texture Unit, STU*), evolución del Método de Unidad de Textura (*Texture Unit, TU*) de He and Le Wang.

Para el proyecto se utilizarán las mismas imágenes que se extrajeron de las quemas controladas de Gestosa en 2001. Al final se comentarán los resultados haciendo una valoración de los métodos más eficaces en vistas a integrar los resultados de este trabajo al programa de detección de columnas de humo desarrollado por los componentes del proyecto INFLAME.

2. Textura

2.1. Concepto de textura

Antes de dar una definición, se va a introducir la relevancia de la textura en este proyecto. La textura es una característica muy importante para el análisis y procesamiento de distintos tipos de imágenes, como son imágenes naturales, imágenes adquiridas mediante sistemas ópticos, etc. La textura juega un papel importante en el reconocimiento e interpretación de datos en sistemas de imágenes visuales. El análisis de textura comprende un interesante campo de investigación en el área de visión por ordenador, procesamiento de imágenes y reconocimiento de patrones. Son numerosas las técnicas que se han desarrollado para la extracción de características de textura, segmentación, clasificación y síntesis.

El análisis de textura es muy relevante en la caracterización de imágenes que no exhiben fronteras claras entre diferentes objetos dentro de la imagen. Esto se puede observar en las imágenes de humo donde existen anomalías en su forma y aspecto. Por esta razón, el análisis de texturas toma un papel crucial en este estudio.

Aunque no existe una definición formal de textura, se puede decir que se entiende por aquel descriptor que proporciona intuitivamente medidas de propiedades tales como el suavizado, la regularidad, la granularidad o la rugosidad. Existen principalmente tres métodos en el procesamiento de imágenes para describir la textura de una región, y son los estadísticos, los estructurales, y los espectrales.

Hace más de 30 años Haralick propuso un conjunto de 14 medidas de textura basadas en la dependencia espacial de los tonos de grises. (Haralick et al., 1973).

La textura de una imagen es una cuantificación de la variación espacial de valores de tono que es imposible definirla precisamente por su carácter sensorial. El uso de la textura de una imagen proviene de la habilidad innata de los humanos de reconocer diferencias entre texturas.

2.2. Imágenes a color

El empleo del color en el procesamiento de imágenes está motivado por dos factores principales. Primero, en el análisis automático de imágenes, el color representa un potente descriptor que a menudo simplifica la identificación de un objeto. Segundo, en el análisis de imágenes realizadas por seres humanos, el interés por el color reside en que nuestro ojo es capaz de discernir miles de matices e intensidades de color, en comparación con sólo dos docenas de niveles de grises.

El procesamiento de imágenes a color se divide en dos áreas fundamentales: el procesamiento del color real (las imágenes se adquieren mediante un sensor de color, como una cámara de televisión o un escáner de color) y el falso color (asignar un nivel de color a una determinada intensidad o rango de intensidades monocromáticas). Dada su calidad y los avances en las técnicas de procesado de imágenes en color real, las imágenes empleadas en el presente trabajo son de color real (24 bits por píxel).

Debido a la estructura del ojo humano, todos los colores se ven como combinaciones variables de los tres colores primarios: rojo, verde y azul. La CIE (Comisión Internacional de Iluminación) designó los valores específicos de sus longitudes de onda: azul = 435.8 nm, verde = 546.1 nm, rojo = 700 nm. Pero el hecho de determinar tres longitudes de onda específicas con el fin de la estandarización no implica que estas tres componentes fijas puedan generar ellas solas todos los colores del espectro. Los colores primarios se pueden sumar para obtener los colores secundarios de luz: magenta, cián y amarillo. Mezclando los tres colores primarios, o uno secundario con su primario opuesto en las proporciones adecuadas se obtiene luz blanca.

Un modelo de color es la especificación de un sistema de coordenadas tridimensional y de un subespacio de este sistema en el que cada color queda representado por un único punto. Por tanto su objetivo es facilitar la especificación de los colores de forma normalizada y aceptada genéricamente. La mayoría de los modelos de color empleados actualmente están orientados hacia el hardware (monitores a color e impresoras) o bien hacia aplicaciones donde se pretende manipular el color. Dentro de los modelos orientados hacia el hardware encontramos: RGB (iniciales de Red – rojo-, Green – verde- y Blue –azul-) para monitores y cámaras de vídeo a color; CMY, (iniciales de Cyan –cián-, Magenta –magenta- y Yellow –

amarillo-) para impresoras a color; YIQ para emisión de televisión en color; la Y corresponde a la luminancia, y la I y la Q son dos componentes (o coordenadas) cromáticas denominadas fase y cuadratura, respectivamente. Entre los modelos que se utilizan frecuentemente en la manipulación de imágenes a color el más importante es el HSI (iniciales de Hue –tono-, Saturation –saturación- Intensity –intensidad-) también conocido como HSV (Value –valor-). Los modelos de color utilizados más frecuentemente para el procesado de imágenes son los RGB, YIQ y HSI. El modelo de color que vamos a emplear en el presente proyecto es el modelo RGB.

En el modelo de color RGB de la figura 1 cada color aparece con sus componentes espectrales primarias de rojo, verde y azul. Está basado en un sistema de coordenadas cartesianas y el subespacio de color de interés es el cubo de la siguiente figura, en la que los valores RGB están en los tres vértices. El cian, magenta y amarillo en otros tres vértices; el negro en el origen y el blanco en el vértice opuesto al origen.

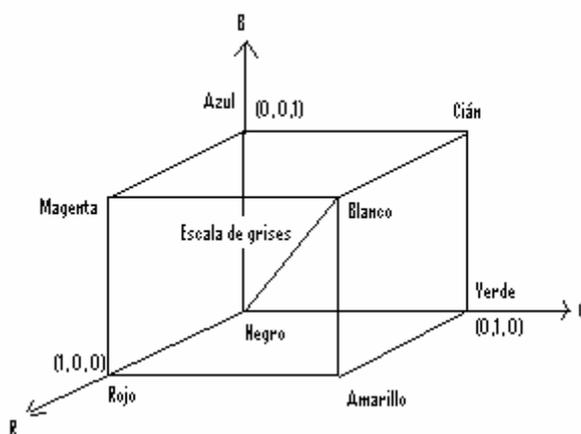


Figura 1. Sistema de coordenadas cartesianas RGB

En este modelo la escala de grises se extiende del negro al blanco a lo largo de una diagonal del cubo, y los colores son puntos del cubo o de su interior, definidos por vectores que se extienden desde el origen. Por conveniencia, se supone que todos los valores de color han sido normalizados, de forma que el cubo de la figura es el cubo unidad. Es decir, todos los valores de R, G y B pertenecen al intervalo $[0,1]$.

Cada píxel de la imagen en color se implementa en la memoria del ordenador mediante 3 octetos o bytes. Cada uno de estos bytes está compuesto por 8 bits. Para normalizar, se emplean las siguientes ecuaciones:

$$r = \frac{R}{R + G + B} \quad \text{Ecuación 1}$$

$$g = \frac{G}{R + G + B} \quad \text{Ecuación 2}$$

$$b = \frac{B}{R + G + B} \quad \text{Ecuación 3}$$

En la fórmula anterior R, G y B son los valores iniciales de los octetos rojo, verde y azul respectivamente de cada píxel. Trabajar con coordenadas normalizadas es ventajoso ya que permite eliminar ciertos efectos de iluminación y brillo de las imágenes digitales. Sin embargo, en este caso no es aconsejable su uso, ya que se ha comprobado que la normalización de coordenadas antes de aplicar métodos de texturas reduce considerablemente la escala de niveles de intensidad. En el presente trabajo, los valores RGB van a pertenecer al intervalo [0,255], dado que se manejan imágenes de color real donde cada componente de color se representa mediante un octeto (256 posibles valores); los tres octetos forman el píxel. Todas las imágenes presentan el formato BMP, con color real. Las imágenes en formato BMP tienen una cabecera que contiene la información que caracteriza a dicha imagen: tamaño, número de filas, número de columnas, número de bits por píxel, etc.

Las imágenes del modelo de color RGB consisten en tres planos de imagen independientes, uno por cada color primario. Por ello se dice que cada uno de estos planos tiene un significado físico. Sin embargo, cuando llegan a un monitor RGB, estas tres imágenes se combinan en la pantalla fosforescente para producir una imagen en color compuesta. El empleo del modelo RGB para el procesamiento adquiere sentido cuando las propias imágenes están expresadas de forma natural en términos de tres planos de color. Además, la mayoría de

las cámaras de color empleadas para la adquisición de imágenes utilizan el formato RGB, lo que ya constituye por sí solo un buen motivo para emplear este modelo. En la figura 2 se muestra una visión esquemática de los tres planos independientes de color que componen una imagen RGB de tamaño $N \times M$ píxeles:

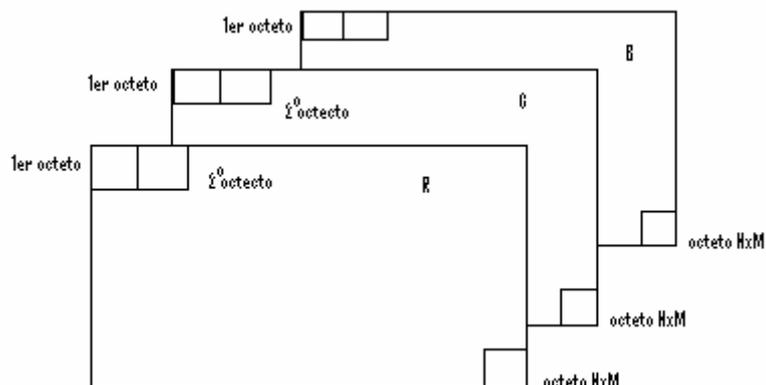


Figura 2. Los tres planos que componen una imagen RGB.

2.3. Descriptores de textura

Los tres métodos más importantes en el procesamiento de imágenes para describir la textura de una región son los estadísticos, estructurales y espectrales.

- Las soluciones **estadísticas** proporcionan características de texturas tales como la suavidad, rugosidad, y otras similares.
- Las técnicas **estructurales** tratan de la composición de primitivas de imágenes, por ejemplo, la descripción de texturas basadas en líneas paralelas igualmente espaciadas.
- Las técnicas **espectrales** se basan en las propiedades del espectro de Fourier y se utilizan principalmente para detectar periodicidades globales de la imagen (esto se hace mediante la identificación en el espectro de picos estrechos y de elevada energía).

Entre los métodos estadísticos existen en la bibliografía diferentes formas de medir la textura en una imagen, estas pueden ser de Primer, Segundo o de Tercer orden:

- **Primer orden:** las medidas texturales de primer orden son calculadas a partir de los valores de gris originales de la imagen y su frecuencia, como la media, varianza, desviación estándar. En estas medidas no se considera la relación entre los píxeles.
- **Segundo Orden:** son las medidas que consideran la relación de co-ocurrencia entre grupos de dos píxeles de la imagen original y a una distancia dada.
- **Tercer y más Orden,** se consideran las relaciones entre 3 y más píxeles. Si bien su cálculo es teóricamente posible, no se implementan pues requieren mucho tiempo de cálculo (aun con computadoras poderosas) y su resultado es de difícil interpretación. La matriz de co-ocurrencia para el cálculo de la textura que se describe en este documento es una medida basada en estadísticas de segundo orden.

2.3.1. Histograma

Uno de los métodos más simples consiste en calcular los estadísticos de primer orden a partir del histograma de la imagen.

Sea $\Phi(i)$ el número de puntos cuya intensidad es i en la imagen y A el área total de la misma (o número total de píxeles). La probabilidad de ocurrencia de la intensidad i -ésima en la imagen, o en otros términos, el valor del histograma en cada punto i ($i = 0 \dots L-1$) viene dado por la ecuación 4.

$$h(i) = \frac{\Phi(i)}{A}$$

Ecuación 4. Valor del histograma en cada punto.

Donde L es el número de niveles cuantificados de gris (o de cada color primario R, G y B). En este trabajo para cada imagen se obtendrán tres histogramas, uno para cada componente de color. Dado que se trabaja con imágenes de color real, $L=256$ para cada uno de los histogramas. En el caso de que no se estudiaran por separado los tres colores primarios,

$L = 224$, lo que supondría tener cerca de 17 millones de niveles de intensidad para un único histograma.

El histograma ofrece mucha información acerca de la frecuencia de distribución de un conjunto de puntos, ya sea aleatorio o determinista. De hecho, el histograma equivale a la función densidad de probabilidad empleada en el ámbito de la estadística. Sin embargo, en el análisis mediante métodos estadísticos del contenido de textura de una imagen, no basta el empleo del histograma. Interesa obtener una serie de descriptores, cada uno de los cuales tiene contenido diferente de información. Se deducen a partir del histograma, y son los siguientes:

1) Media. Es la medida de la tendencia general, esto es, del color que predomina en una imagen. Siendo L el número de niveles discretos de color (escala de grises o bien cada plano de la imagen RGB), X_i es la variable aleatoria que indica la intensidad de una imagen discreta ($i=0, \dots, L-1$). A partir de la Ec.1 se deduce el valor del histograma en cada punto de la escala. El color medio de un conjunto de píxeles viene dado por la ecuación 5.

$$\bar{X} = \sum_{i=0}^{L-1} X_i \cdot h(i)$$

Ecuación 5. Media.

2) Desviación estándar. Empleando la misma simbología que en el descriptor anterior, la fórmula que expresa la desviación estándar es la siguiente:

$$\sigma = \sqrt{\sum_{i=0}^{L-1} (X_i - \bar{X})^2 \cdot h(i)}$$

Ecuación 6. Desviación estándar.

Elevada al cuadrado se denomina varianza, que proporciona una medida del contraste del nivel de gris que se puede utilizar para establecer descriptores de suavidad relativa. Es decir, un histograma estrecho indicaría poco contraste en la región, porque la imagen sólo emplea en su representación pocos niveles de gris. De esta forma, la varianza se usa para medir actividades locales de la amplitud. Por ejemplo, la medida obtenida mediante la

ecuación 7 es cero para áreas de intensidad constante ($\sigma^2(i) = 0$ si todas las X_i tienen el mismo valor) y se aproxima a 1 para valores grandes de $\sigma^2(i)$.

$$R = 1 - \frac{1}{1 + \sigma^2(i)}$$

Ecuación 7

3) Tercer momento. Es una medida de la desviación del histograma con respecto a su media. A partir de la media y del histograma, se obtiene como:

$$\mu_3 = \sum_{i=0}^{L-1} (X_i - \bar{X})^3 \cdot h(i)$$

Ecuación 8. Tercer momento.

4) Entropía. Esta componente mide la aleatoriedad y se define como la información media generada por una fuente. Para una imagen digital considerada como una fuente de píxeles independientes, su entropía se puede estimar a partir del histograma de la siguiente forma:

$$H = - \sum_{i=0}^{L-1} h(i) \cdot \log_2(h(i))$$

Ecuación 9. Entropía.

Para un número dado de niveles de gris, L , la entropía de una fuente es máxima para distribuciones uniformes. En dicho caso, $h(i) = 1 / L$ para $i = 0, \dots, L-1$. Quedaría entonces como:

$$\text{máx } H = - \sum_{i=0}^{L-1} 1/L \cdot \log_2(1/L) = \log_2 L$$

Ecuación 10. Entropía máxima.

Su unidad media es el bit.

Las medidas de textura calculadas utilizando solamente histogramas presentan la limitación de no contener información referente a la posición relativa de cada píxel con respecto a los otros. Una forma de introducir este tipo de información en el proceso de

análisis de textura consiste en considerar no solamente la distribución de intensidades, sino también las posiciones de píxeles que tienen iguales, o casi iguales, valores de intensidad. Esto se logra con la introducción de la matriz de co-ocurrencia.

a. Blanco y Negro

Se van a presentar de dos modos distintos el método del histograma. Por un lado se usarán imágenes en escala de grises y por otro, imágenes a color.

Para convertir las imágenes, que originalmente están en color, a escala de grises, se acoplar las tres capas de colores en una sola capa. Para ello se halla la media aritmética de las tres capas, es decir, los píxeles de las tres capas se suman y se dividen entre 3.

$$[(1, 1, 1) + (1, 1, 2) + (1, 1, 3)] / 3 = \text{píxel en b\&n}$$

b. Color

Para trabajar con imágenes a color, se usa cada capa por separado. Para estas imágenes a color se calculan los histogramas por separado para cada capa de color R + G + B. Aunque se obtienen unos histogramas por separado para cada color, a la hora de trabajar con ellos para medir distancias entre distribuciones se unen los tres histogramas en uno solo.

$$[\text{HistogColor}] = [\text{HistogR}, \text{HistogG}, \text{HistogB}]$$

La información de color que se obtiene con las imágenes da muy buen resultado a la hora de discriminar zonas de la imagen pertenecientes a una clase o a otra. Estos resultados se podrán observar en la parte práctica del trabajo.

2.3.2. Matriz de Co-ocurrencia

- Introducción

Aparte de las variables de textura basadas en estadísticas de 1er orden (media, desviación estándar, varianza) que se ha presentado en el apartado anterior, en Jensen (1996) se propusieron otras variables estadísticas de segundo orden, basadas en la matriz de co-

ocurrencia, entre las mas usadas para medir la textura. La asunción es que la información textural en una imagen esta contenida en la relación espacial que los tonos de grises tienen entre ellos. Esas relaciones están especificadas en la matriz de co-ocurrencia espacial (o de niveles de gris) que son computadas en una dirección especifica (o bien para todas: 0°, 45°, 90° y 135°) entre los píxeles vecinos dentro de una ventana móvil dentro en la imagen.

El método mas comúnmente utilizado para medir matemáticamente la textura es la matriz de co-ocurrencia de niveles de grises o con sus siglas en ingles GLCM (Grey Level Co-occurrence Matrix), basadas en estadísticas de 2do orden. Es un histograma de los niveles de grises de dos dimensiones para un par de píxeles (píxel de referencia y vecino). Esta matriz aproxima la probabilidad de distribución conjunta de un par de píxeles.

- **Concepto de Matriz de Co-ocurrencia**

La matriz de co-ocurrencia describe la frecuencia con que un nivel de gris aparece en relación espacial específica con otro nivel de gris, dentro del área de una ventana determinada. La matriz de co-ocurrencia es un resumen de la forma en que los valores de los píxeles aparecen al lado de otro valor en una pequeña ventana. Normalmente el procedimiento de generación de imágenes de textura requiere que el analista defina cinco variables:

- i) Tamaño de la ventana
- ii) Banda espectral de entrada
- iii) Las texturas derivadas
- iv) Cuantización (número de bits) del canal de salida
- v) La componente espacial (la distancia interpíxel y el ángulo para el cómputo de la co-ocurrencia).

Respecto del tamaño de la ventana, esta debe ser cuadrada y con número impar de píxeles. El resultado del cálculo de la textura (figura 3) es un único número que representa la

ventana completa, el cual es colocado en el lugar del píxel central. Luego, la ventana se mueve un píxel y el cálculo se repite calculando una nueva matriz de co-ocurrencia para esta nueva ventana y resultando un nuevo valor, para el píxel central de esta nueva posición de la ventana. De este modo se construye toda una nueva imagen con valores de texturas.

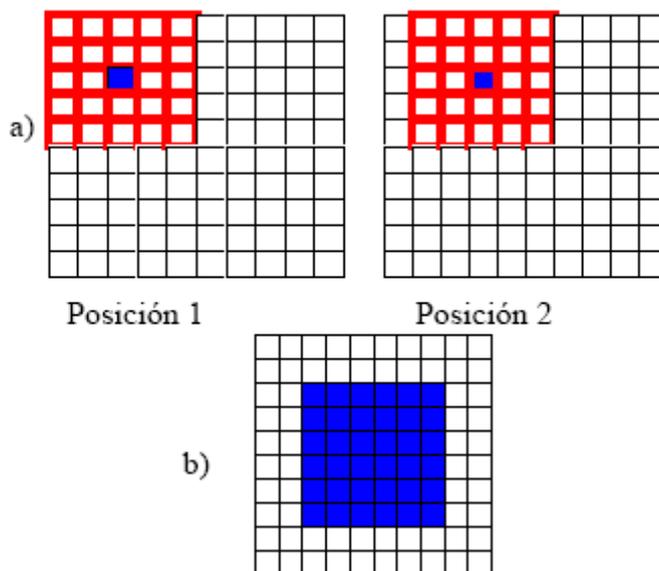


Figura 3. Simulación del cálculo de la matriz de co-ocurrencia

En a) se muestra sobre una imagen de dimensiones 10x10 píxeles, una ventana móvil de 5x5 en dos posiciones y el píxel central que recibe el resultado. En b) los píxeles que reciben el resultado y las 2 filas y las 2 columnas del borde de la imagen que reciben el valor de textura calculados en los píxeles cercanos.

Cada celda de la ventana debe situarse en una celda que esté ocupada en la imagen original. Esto significa que el píxel central de la ventana No puede ocupar un borde la imagen. Si una ventana tiene dimensiones $N \times N$, una franja de $(N-1)/2$ píxeles alrededor de la imagen permanecerá sin resultados (Figura 1). Usualmente los píxeles de borde representan una pequeña fracción de las imágenes, por lo cual es un problema menor. Sin embargo, si la imagen es muy pequeña o la ventana muy grande, este efecto debe considerarse en el análisis

de los resultados. Una forma de solucionar este problema es llenar esas celdas con el valor calculado para el píxel más cercano.

Por otra parte, el tamaño relativo de la ventana y de los objetos en la imagen determina la utilidad de ésta medida para la clasificación. Es recomendable que la ventana sea menor que el objeto y lo suficientemente grande como para capturar la variabilidad del mismo. Por ejemplo en un bosque la textura esta determinada por las luces y sombras de las copas. Una ventana con el tamaño de un solo árbol no medirá la textura del bosque. Otra ventana cubriendo todo el bosque y los campos vecinos a él, tampoco medirá la textura del mismo. La relación espacial entre el píxel de referencia y su vecino puede ser en cualquiera de las 8 direcciones (N, S, E, O y las 4 diagonales), pero solo se toman cuatro, ya que la N es opuesta a la S y en vez de contarlas separadamente hay formas mas sencillas de medirlas (matriz simétrica, que mas adelante se detalla). Cuando se habla de una relación “espacialmente invariante” (figura 4) se eligen las cuatro direcciones N, NE, E y SE y se promedian. (Esto también se expresa respectivamente como 0° , 45° , 90° y 135°).

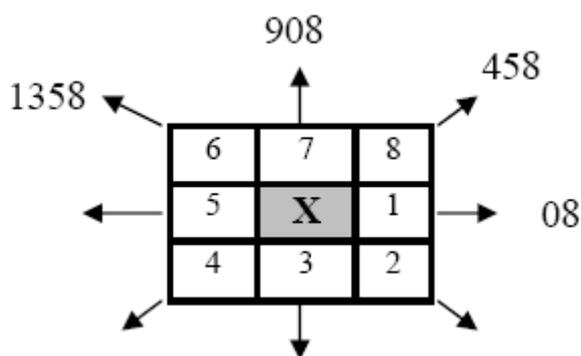


Figura 4. Los 8 vecinos del píxel X de acuerdo al ángulo utilizado en el cálculo de la matriz de co-ocurrencia.

Todas estas variables podrían generar muchos datos: asumiendo que se usan 7 medidas de texturas (aunque pueden ser más), 6 bandas espectrales (a menudo más), tamaños de ventanas que varían entre 3x3 y 21x21 (diez tamaños diferentes, pero... ¿por qué parar allí?) 3 niveles de cuantización del canal de salida (8, 16 y 32 bits) y 4 direcciones posibles (componente espacial) el resultado podrían ser mas de 5000 imágenes de textura para una sola aplicación. Esto sobrepasa a los mas sofisticados clasificadores. No hay forma de predecir con

certeza cuáles medidas serán de mayor utilidad. Sin embargo existen algunos conceptos generales para considerar:

- La inspección visual de algunas bandas de entrada pueden ayudar a determinar no usarlos. Por ejemplo, en estudios de vegetación la banda del rojo y el infrarrojo cercano (NIR) suelen ser los mas útiles, o bien alguna combinación de ellos como un índice de vegetación (NDVI). El Análisis de Componentes Principales también puede ayudar a reducir las bandas de entrada.
- La inspección visual de una imagen también puede mostrar alguna direccionalidad, si no la hubiera la mejor opción es usar la espacialmente invariante.
- Muchas de la medidas texturales están correlacionadas entre si, en realidad existen pocas verdaderamente independientes.
- El mejor tamaño de la ventana se podrá estimar inspeccionando visualmente la imagen.

Seleccionar un conjunto de variables de textura a usar puede ser problemático. En general, la textura es una variable específica para cada imagen, el uso exitoso del análisis textural en una aplicación no implica necesariamente aplicabilidad global. Por lo tanto, la selección de las variables de textura debería basarse en el estudio iterativo del conjunto imagen particular y condiciones del objeto a estudiar. (Franklin, 2001).

- Cálculo de la Matriz de Co-ocurrencia

En la figura 5 se representa la imagen prueba u original donde los valores corresponden a Niveles de Grises. La imagen tiene 4 píxeles de lado y 4 niveles de grises: 0, 1, 2 y 3. (Haralick et al. 1973).

Se aclara que en este caso se toman los valores de gris de la imagen en su totalidad para realizar los cálculos, dando como resultado solo un valor que representa a toda la imagen. Cuando se trabaja con imágenes reales de mayores dimensiones, la secuencia de cálculo es la que ya fuera presentada anteriormente.

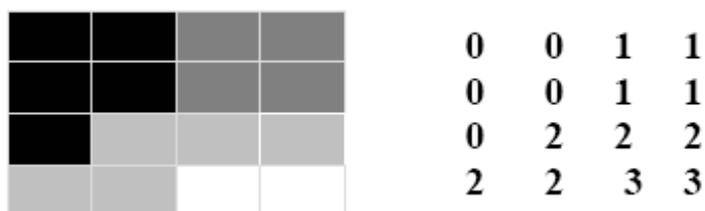


Figura 5. Imagen prueba cuyas dimensiones son 4x4 píxeles con cuatro valores de niveles de gris (0, 1, 2 y 3).

- Relación espacial entre dos píxeles

La Matriz de Co-ocurrencia considera la relación espacial entre dos píxeles, llamados píxel de referencia y píxel vecino. Por ejemplo, si se escoge el píxel vecino que está situado un píxel a la derecha de cada píxel de referencia, esto se expresa como (1,0): 1 píxel en la dirección x, 0 píxel en la dirección y.

Cada píxel en la ventana se va convirtiendo sucesivamente en el píxel de referencia, empezando por el ubicado arriba a la izquierda y finalizando abajo a la derecha. Los píxeles ubicados en el margen derecho de la imagen original, no tienen vecino a la derecha por lo tanto no son usados en el cómputo.

Se pueden utilizar diferentes relaciones entre píxeles, por ejemplo:

(-1,0) un píxel a la izquierda del píxel de referencia

(1,1) un píxel a la derecha y un píxel abajo (en diagonal).

- Distancia entre píxeles

Normalmente se utiliza un píxel de separación (un píxel de referencia y su inmediato vecino). Cuando la ventana es suficientemente grande, se puede usar una separación mayor, sin que haya diferencias en la metodología de su cálculo.

Las posibles combinaciones de niveles de grises para la imagen de prueba se presentan en la Tabla 1, estas etiquetas no se volverán a mostrar en las matrices de coocurrencia.

Pixel Vecino Pixel de Referencia	0	1	2	3
0	(0,0)	(1,0)	(2,0)	(3,0)
1	(1,0)	(1,1)	(2,1)	(3,1)
2	(2,0)	(1,2)	(2,2)	(3,2)
3	(3,0)	(1,3)	(2,3)	(3,3)

Tabla 1. Todas las posibles combinaciones de los cuatro niveles de gris de la imagen de prueba

La primera celda debe ser llenada con la cantidad de veces que ocurre la combinación 0,0. Cuantas veces, en el área de la ventana un píxel con valor de gris igual a 0 (píxel vecino), está situado a la derecha de otro píxel con valor 0 (píxel de referencia).

Existen, por lo tanto diferentes matrices de co-ocurrencia para cada relación espacial, según se considere el vecino de arriba, al costado o en diagonal.

En la Tabla 2 se muestra la matriz de co-ocurrencia para la relación espacial (1,0). Esta matriz se interpreta de la siguiente manera: En la imagen de prueba, dos veces el píxel de referencia es 0 y su vecino a la derecha es también 0 (Primera celda). Dos veces el píxel de referencia es 0 y su vecino a la derecha es 1.

2	2	1	0
0	2	0	0
0	0	3	1
0	0	0	1

Tabla 2. Matriz de co-ocurrencia (1,0) para la imagen prueba

- Normalización de la matriz

En la matriz precedente, se cuentan cada píxel de referencia con su vecino a la derecha. Si el cálculo se realiza sólo de este modo, usando sólo una dirección, entonces el número de veces que aparece la combinación 2,3 no es el mismo que la combinación 3,2 (por ejemplo el

3 esta a la derecha del 2 tres veces, pero a la izquierda sólo una), por lo tanto la matriz no es simétrica respecto de la diagonal.

Sin embargo, la simetría es necesaria para el cálculo, esto se logra si cada par de píxeles se cuentan dos veces: una vez a la derecha y otra vez a la izquierda (se intercambian los píxeles de referencia y vecino en el segundo cálculo).

Para obtener una matriz simétrica, la forma más sencilla en vez de contar dos veces, es sumarle a esta matriz su matriz traspuesta. La matriz traspuesta se logra intercambiando las filas y columnas de la matriz original. Sumando cada elemento de la matriz original y su traspuesta, se llega a la matriz simétrica de la Tabla 3.

4	2	1	0
2	4	0	0
1	0	6	1
0	0	1	2

Tabla 3. Matriz simétrica para una relación horizontal (derecha + izquierda) de la imagen prueba

Una vez obtenida la matriz simétrica, el paso siguiente es expresar esta matriz como probabilidad. La definición mas simple de la probabilidad es: "el número de veces que un evento ocurre, dividido por el número total de posibles eventos" y la ecuación para su cálculo es:

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}}$$

Ecuación 11

Donde:

i es el número de filas y j el número de columnas

V es el valor de la celda i,j en la ventana

$P_{i,j}$ es la probabilidad en la celda i,j

N es el número de filas o columnas.

Considerando la imagen de prueba de 4 x 4 píxeles, y la relación (1,0) el número total de posibles pares es de 12, como muestra la figura 6, y para una relación horizontal (derecha mas izquierda) ese numero se duplica (24).

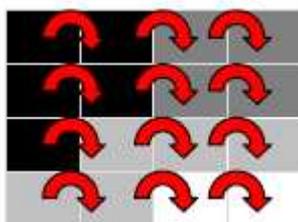


Figura 6. Posibles pares que se pueden tomar con la relación (1,0)

Doce pares de píxeles para una relación a la izquierda (1,0). Considerando también la relación a la derecha (-1,0) para construir la matriz horizontal, los pares se duplican.

Observando la matriz horizontal de la Tabla 3, vemos que, por ejemplo, la combinación 2,2 aparece 6 veces de las 24 posibles (12 a la derecha y 12 a la izquierda) y la combinación 2,3 solo 1 vez.

La Combinación 2,2 ocurre 6 veces sobre 24 posibles, por lo que la probabilidad es de $\frac{1}{4}$ o 0.250. Mientras que la combinación 2,3 es de $\frac{1}{24}$ o 0.042.

La ecuación anterior transforma la matriz de co-ocurrencia en una aproximación de tabla de probabilidad. Decimos, que es una aproximación, porque una verdadera probabilidad requiere de valores continuos, y los valores de grises son valores enteros, por lo tanto discretos.

Este proceso se denomina Normalización de la matriz. Aplicando esta ecuación a la matriz simétrica de la Tabla 3 obtenemos la matriz de la Tabla 4, donde la sumatoria de todos los elementos debe ser igual a 1, pues esta normalizada.

0.166 (4/24)	0.083 (2/24)	0.042 (1/24)	0 (0/24)
0.083	0.166	0	0
0.042	0	0.250	0.042
0	0	0.042	0.083

Tabla 4 – Matriz Normalizada horizontal de la matriz original

Se asume que toda la información esta contenida en la matriz de dependencia espacial desarrolladas para las 4 direcciones de la ventana de muestra. En general, cuanto mayor es el número de la diagonal en la matriz de co-ocurrencia, mas homogénea es la textura en esa parte de la imagen que está siendo analizada.

Con respecto a la matriz de co-ocurrencia simétrica y normalizada hay algunos aspectos a resaltar:

- Los elementos de la diagonal representan pares de píxeles que no tienen diferencias en su nivel de gris. Si estos elementos tienen probabilidades grandes, entonces la imagen no muestra mucho contraste, la mayoría de los píxeles son idénticos a sus vecinos.
- Sumando los valores de la diagonal tenemos la probabilidad que un píxel tenga el mismo nivel de gris que su vecino.
- Las líneas paralelas a la diagonal separadas una celda, representan los pares de píxeles con una diferencia de 1 nivel de gris. De la misma manera sumando los elementos separados dos celdas de la diagonal, tenemos los pares de píxeles con dos valores de grises de diferencia. A medida que nos alejamos de la diagonal la diferencia entre niveles de grises es mayor.
- Sumando los valores de estas diagonales paralelas obtenemos la probabilidad que un píxel tenga 1, 2, 3, etc. niveles de grises de diferencia con su vecino.

Esta suma de las diagonales se denomina GLDV (Grey Level Difference Vector) y también es utilizado como una medida textural en vez de la GLCM, aunque aquí no se detalla.

- Propiedades de la matriz

Cuadrada:

El rango de los valores de los píxeles de referencia y el de los vecinos es el mismo, por lo tanto las filas y las columnas tienen idéntico número.

Tiene el mismo número de filas y columnas que el número de bits de la imagen.

La imagen de prueba tiene solo 4 valores posibles (0, 1, 2 y 3), es decir es una imagen de 2 bits ($2^2 = 4$). Los datos de 8 bits (como una banda original del satélite Landsat) tiene 256 ($2^8 = 256$) posibles valores, así la matriz de co-ocurrencia es de 256×256 , con 65536 celdas. Datos en 16 bits (Ej. Una imagen Radarsat) origina una matriz de 65536×65536 con 429.496.720 celdas.

Es simétrica con respecto a la diagonal

Una matriz simétrica significa que los mismos valores ocurren en las celdas opuestas a la diagonal. Por ejemplo, el valor en la celda 3,2 debería ser el mismo que el valor en la celda 2,3 para que la matriz sea simétrica.

- **Medidas de textura**

Hasta este punto se ha detallado como se crea una matriz normalizada, expresada como probabilidad, para una determinada relación espacial entre dos píxeles vecinos. Una vez construida, de esta matriz pueden derivarse diferentes medidas, en esta sección se definen algunas de ellas, y se desarrollan con mayor profundidad las medidas cuyos cálculos pueden ser realizados manualmente por su sencillez.

Las siguientes son una breve explicación de algunas medidas texturales:

• **Homogeneidad**

Se calcula mediante la ecuación 12:

$$\sum_{i,j=0}^{N-1} P_{i,j} / 1 + (i - j)^2$$

Ecuación 12

Siendo $P_{i,j}$ la probabilidad de co-ocurrencia de los valores de gris i y j , para una distancia dada. Así tenemos para el primer elemento de la matriz una probabilidad de 0.166 y los niveles de gris de los píxeles de referencia y píxel vecino de 0, por lo tanto: $0.166/1 + (0-0)^2 = 0.166$.

Del mismo modo para el segundo elemento (0,1) tenemos $0.083/1 + (0-1)^2 = 0.0415$. Sumando el resultado para todos los elementos obtenemos el valor de la medida de Homogeneidad para esta imagen y para esta relación espacial.

$$0.166/1 + 0.083/2 + 0.042/5 + 0/10 + 0.083/2 + 0.166/1 + 0/2 + 0/5 + 0.042/5 + 0/2 + 0.25/1 + 0.042/2 + 0/10 + 0/5 + 0.042/2 + 0.083/1 = 0.807$$

Otra forma de realizar el cálculo es en forma matricial, multiplicando la matriz de probabilidades (Tabla 4) por la matriz de pesos. En la Tabla 5 se presentan los pesos para calcular la homogeneidad, los pesos son menores a medida que nos alejamos de la diagonal. Sumando todos los elementos de la matriz resultado (Tabla 6) obtenemos el valor de la medida de homogeneidad.

1	0.5	0.2	0.1
0.5	1	0.5	0.2
0.2	0.5	1	0.5
0.1	0.2	0.5	1

Tabla 5. Matriz de los pesos utilizados en el cálculo de la homogeneidad

0.166	0.042	0.08	0
0.042	0.166	0	0
0.08	0	0.250	0.021
0	0	0.021	0.083

Σ de todos los elementos = 0.807

Tabla 6. Matriz resultado de la multiplicación de la matriz normalizada horizontal y de la matriz de pesos de homogeneidad.

La Homogeneidad es alta cuando la matriz de co-ocurrencia se concentra a lo largo de la diagonal. Esto ocurre cuando la imagen es localmente homogénea de acuerdo al tamaño de la ventana.

• **Contraste**

Es lo opuesto a la homogeneidad, es decir es una medida de la variación local en una imagen. Tiene un valor alto cuando la región dentro de la escala de la ventana tiene un alto contraste. Se calcula mediante la ecuación 13.

$$\sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2$$

Ecuación 13

La matriz de pesos, toma valores que crecen exponencialmente a medida que nos alejamos de la diagonal (0,1,4,9, etc.) Para la diagonal central $(0-0)^2 = (1-1)^2 = 0$. Para la primer diagonal paralela $(1-0)^2 = (0-1)^2 = 1$ para la segunda diagonal paralela $(2-0)^2 = (0-2)^2 = 4$ y la tercera $(3-0)^2 = (0-3)^2 = 9$.

• **Desviación Estándar**

Es la desviación estándar de los niveles de grises en la ventana. Es alta cuando la desviación estándar en los niveles de grises dentro de la ventana es también alta. Las ecuaciones para el cálculo de la varianza (ecuaciones 14 y 15), dan el mismo resultado tanto para i como para j, pues la matriz es simétrica.

$$\sigma_i^2 = \sum_{i,j=0}^{N-1} P_{i,j} (i - \mu_i)^2$$

$$\sigma_j^2 = \sum_{i,j=0}^{N-1} P_{i,j} (i - \mu_j)^2$$

Ecuaciones 14 y 15

Esta medida se basa en la media y la dispersión alrededor de la media de los valores de las celdas de la matriz de co-ocurrencia. Como la varianza utiliza específicamente la

combinación entre los píxeles de referencia y vecino, no es la misma que la varianza de los niveles de grises de la imagen original.

• **Entropía**

Es alta cuando los elementos de la matriz de concurrencia tienen relativamente valores iguales. Es baja cuando los elementos son cercanos a 0 o 1 (por ejemplo cuando la imagen es uniforme dentro de la ventana).

$$\sum_{i,j}^{N-1} -P_{i,j} \ln(P_{i,j})$$

Ecuación 16

Se asume que $0 \cdot \ln(0) = 0$

Si, $P_{i,j}$ es una probabilidad y toma valores entre 0 y 1, entonces el $\ln(P_{i,j})$ siempre tomará valores de 0 o negativos. Cuanto más pequeño sea el valor de $P_{i,j}$, es decir que la ocurrencia de esa combinación de píxeles es poco común, el valor absoluto de $\ln(P_{i,j})$ será mayor.

• **Correlación**

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$$

Ecuación 17

El resultado es entre -1 y 1.

Como surge de la ecuación esta medida se calcula de una forma diferente a las anteriores medidas, por lo cual la información que suministra es esencialmente distinta, es independiente de las otras medidas. Por lo tanto es esperable que pueda ser usada en combinación con otra medida textural.

Algunas propiedades de la Correlación son:

- Un objeto tiene más alta correlación dentro de él que entre objetos adyacentes.
- Píxeles cercanos están más correlacionados entre sí que los píxeles más distantes.

- **ASM (Angular Second Moment) o Energía**

$$\sum_{i,j=0}^{N-1} P_{i,j}^2$$

Ecuación 18

Esta medida da valores altos cuando en la matriz de concurrencia tiene pocas entradas de gran magnitud, y es baja cuando todas las entradas son similares. Es una medida de la homogeneidad local.

La raíz cuadrada del ASM se denomina Energía o Uniformidad, y también es usada como medida textural.

2.3.3. Simplified Texture Unit (STU)

a. Texture Unit (TU)

- Introducción a la TU

Los métodos de análisis de textura normalmente se dividen en dos grandes categorías.

La primera consiste en el método estructural, donde la textura es considerada como una repetición de algunas primitivas, con una cierta norma de desplazamiento. El ya conocido análisis del espectro de Fourier a menudo se usa para determinar dichas primitivas y la norma de desplazamiento. Varios autores han aplicado este método para la clasificación y caracterización de texturas con una cierta probabilidad de éxito. Pero en la práctica, se pueden encontrar algunos problemas a la hora de identificar las primitivas y de obtener la norma de repetición en imágenes naturales, tales como las imágenes de humo u otras imágenes obtenidas de modo natural.

El segundo gran método usado en el análisis de texturas es el método estadístico. Su objetivo consiste en determinar las propiedades estocásticas de una distribución espacial de niveles de gris en una imagen. La matriz de coocurrencia con niveles de gris es muy usada

pues obtiene dichas características. De hecho, se han usado en la práctica, para imágenes digitales, un conjunto de descriptores obtenidos de la matriz de coocurrencia. Pero algunas veces esta matriz produce resultados insatisfactorios. Algunas razones de ello son las siguientes. En primer lugar, la matriz depende no sólo de las relaciones espaciales de los niveles de gris sino también de la intensidad de fondo de la zona en la que estemos calculando la matriz. En segundo lugar, la información que se obtiene de la matriz a partir de una imagen depende de un vector de desplazamiento dado $\vec{V} = (\Delta x, \Delta y)$ y la elección de este vector es a veces un poco problemático.

Con el descriptor TU conseguimos un nuevo método estadístico de análisis de textura cuyo objetivo busca la caracterización de texturas y la consiguiente discriminación entre ellas.

Para entender el concepto de la unidad de textura TU, podemos considerar la unidad más pequeña pero completa de textura que mejor caracteriza una zona. Esta unidad mínima está dada por un píxel y sus píxeles vecinos en las ocho direcciones de una cuadrícula. Una imagen de textura se caracteriza por su espectro de textura, compuesto por la distribución de todas las unidades de textura TU, dentro de una imagen. Los resultados que se han obtenido con este método demuestran el potencial grandísimo para el análisis de textura.

- Metodología

En una imagen digital, cada píxel tiene alrededor otros ocho píxeles vecinos. Podemos extraer información de textura a partir de una ventana de 3x3 píxeles, que representa la unidad de textura más pequeña posible. El conjunto de estos píxeles se va a denotar de la forma:

$$V = \{v_0, v_1, \dots, v_8\}$$

Donde v_0 representa el valor de intensidad del píxel central y v_i ($i=1,2,\dots,8$) representa el valor de intensidad del píxel vecino i .

Se define la unidad de textura del conjunto V como otro conjunto de ocho elementos:

$$TU = \{e_0, e_1, \dots, e_8\}$$

Donde los e_i ($i=1,2,\dots,8$) se obtienen mediante la fórmula:

$$E_i = \begin{cases} 0, & \text{if } V_i < V_0 \\ 1, & \text{if } V_i = V_0 \\ 2, & \text{if } V_i > V_0 \end{cases} \quad \text{Ecuación 19}$$

Para $i=1,2,\dots,8$. Cada elemento e_i se coloca en la misma posición que ocupaba el píxel i .

Como cada elemento de la TU tiene tres posibles valores, la combinación de los ocho elementos puede dar $3^8=6561$ posibles valores de unidades de textura en total.

El modo de nombrar a los 6561 posibles combinaciones en la TU es mediante la ecuación 20.

$$N_{TU} = \sum_{i=1}^8 e_i \cdot 3^{i-1} \quad \text{Ecuación 20}$$

Donde la NTU representa el número de unidad de textura y e_i es el i -ésimo elemento del conjunto de unidad de textura $TU = \{e_1, e_2, \dots, e_8\}$.

Además, los ocho elementos pueden ser ordenados de modo diferente. Si los ocho elementos son ordenados en el sentido de las agujas del reloj como se observa en la figura 7, el primer elemento puede tomar ocho posibles posiciones desde la parte superior izquierda (a) hasta el píxel medio de la izquierda (h), y entonces los 6561 unidades de textura pueden ser nombrados con la ecuación 20 colocando los ocho elementos en diferente orden (desde a hasta h). Un ejemplo se puede ver en la figura 8.

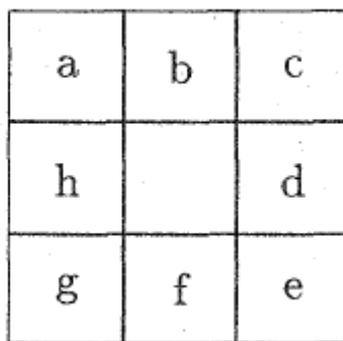


Figura 7. En el sentido de las agujas del reloj, los sucesivos modos de ordenar los ocho elementos de la unidad de textura. El primer elemento e_i puede tomar ocho posibles posiciones desde a hasta h .

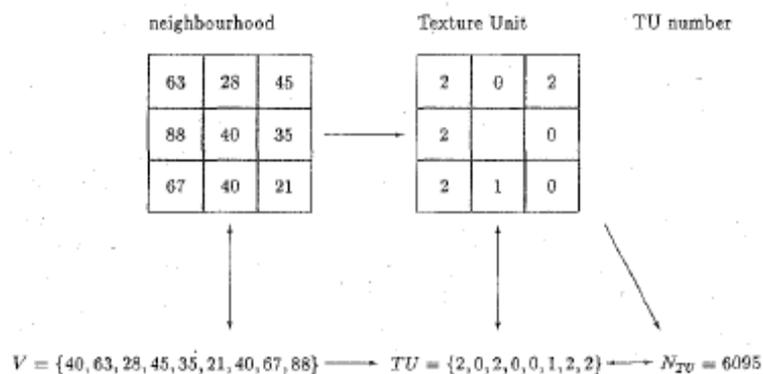


Figura 8. Ejemplo de transformación de un entorno de vecindad en una unidad de textura con el correspondiente número de unidad de textura NTU, tomando $\Delta = 0$.

El conjunto de las 6561 unidades de textura describen el aspecto de la textura local de un píxel dado; esto es, de las relaciones relativas de los niveles de gris entre el píxel central y sus vecinos. Por esto las estadísticas de frecuencia de ocurrencia de todas las unidades de textura sobre toda una región de una imagen deberían revelar información de textura. Llamamos espectro de textura a la distribución de frecuencia de todas las unidades de textura, con el eje de abscisas indicando el número de unidad de textura NTU y en el eje de ordenadas representando su frecuencia de aparición.

En la práctica, una imagen real de textura normalmente está compuesta de dos partes: elementos de textura y ruido aleatorio o fondo de la imagen. Cuanto mayor sea la proporción de elementos de textura comparado con los elementos de ruido aleatorio, mejor podrá ser

percibida dicha textura a los ojos humanos. Cuanto mayor sea el porcentaje de componentes de textura en una imagen, en el espectro de textura dará por resultado una tendencia a formar distribuciones particulares en forma de cimas o picos. Y lo que es más, diferentes imágenes de textura, al tener diferentes unidades de textura tendrán diferentes distribuciones en sus espectros de textura. Es por esto que la textura de una imagen puede perfectamente caracterizarse por su espectro de textura.

Se debe prestar atención a que el método elegido para nombrar las unidades de textura puede afectar a las posiciones relativas de las NTU en el espectro de textura, pero no cambiará al final sus valores de frecuencia de aparición.

Se debe hacer notar también que mientras que la textura local de un píxel dado y sus vecinos se caracteriza perfectamente por la correspondiente unidad de textura, la textura de una imagen de textura se revela por su espectro de textura calculado dentro de una ventana de tamaño apropiado. El tamaño de la ventana depende de la naturaleza de la imagen de textura.

- Ventajas de la TU sobre otros métodos estadísticos

El método de la unidad de textura TU, como se demuestra más extensamente en el documento de Dong-Chen He and Li Wang (1990), presenta cómo el espectro de textura es capaz de revelar información de textura en imágenes digitales y que es capaz de tener un funcionamiento discriminante para diferentes tipos de texturas. Además, cuando comparamos este método con otros métodos estadísticos, encontramos varias ventajas:

1. El método de unidad de textura extrae información de la textura a partir de un píxel dado y un entorno de vecindad de 3x3 píxeles; por ejemplo, simultáneamente tenemos en cuenta las ocho direcciones posibles a partir del píxel central mientras que con otros métodos como el de la matriz de coocurrencia sólo tenemos en cuenta un vector de desplazamiento. Por esto, en este sentido, este nuevo método es más completo para la obtención de propiedades texturales.

2. Desde la definición de los 6561 unidades de textura, el método es independiente de las imágenes que se analicen, es decir, describimos todas las imágenes de textura de la misma forma.
3. La información de textura de una imagen se obtiene en forma de espectro, haciendo posible su aplicación en otros problemas de procesamiento de imágenes, tales como el diseño de filtros digitales.
4. El método TU puede ser fácilmente adaptable al análisis de textura o de forma de imágenes binarias, donde la imagen toma sólo dos posibles valores (0 y 1) para cada elemento de la unidad de textura. El número total de unidades de textura posibles llega a ser $2^8=256$. Por lo que el tiempo de cálculo en el análisis se reduce considerablemente.

b. Mejoras de la TU: STU

Basándonos en un estudio de la Universidad de Córdoba, realizado por M. Prieto, R. Medina Carnicer y otros (2003), vamos a presentar una mejora al método de la unidad de textura TU, llamado Unidad de Textura Simplificada STU, que ofrece mejores resultados que la TU.

- Introducción a la STU

La unidad de textura simplificada STU es un descriptor de texturas de niveles de gris que es una versión, con un coste computacional menor, del ya conocido método de unidad de textura TU. Prieto ha llevado a cabo un estudio comparativo de la capacidad de este método de describir la textura de una región, con la capacidad dada por el descriptor TU y el descriptor de otras dos versiones del mismo TU, conocidos como Local Binary Pattern (LBP) y el Local Binary Pattern with Contrast (LBP/C).

Los resultados de los experimentos permiten afirmar que el nuevo descriptor STU tiene un mejor funcionamiento para regiones de pequeño tamaño, que lo capacita para la

segmentación de texturas desconocidas (no supervisadas) además de obtener mayor exactitud en la localización de fronteras entre distintas regiones de textura.

Este método (STU) combina el uso de un descriptor de textura local, generalmente con un entorno de vecindad de 3×3 , junto con una distribución de los valores de este descriptor local en una región de la imagen para caracterizar su textura. El análisis de disimilaridad entre dos distribuciones puede ser usado para decidir si dos regiones de una imagen son partes de una misma clase de textura.

La unidad de textura (TU) es un descriptor de textura local. Como ya hemos dicho en el apartado anterior fue propuesto por He and Wang. Se ha demostrado por muchos estudios que el TU es un medidor de gran potencia de texturas.

Pero este método tiene varios inconvenientes. El mayor de ellos es que este descriptor puede tomar un amplio rango de valores posibles $TU=[0,6560]$ al mismo tiempo que estos valores no están correlados. Por tanto, no se pueden agrupar. Como consecuencia, las regiones deben tener un tamaño relativamente grande para obtener distribuciones que permitan computar eficazmente y de manera estable medidas de disimilaridad.

Ojala et al. Propuso una versión simplificada del descriptor TU llamada Local Binary Pattern (LBP). El LBP reduce significativamente el rango de posibles valores que puede tomar el descriptor $[0,255]$. Sin embargo, esta simplificación conlleva una pérdida de capacidad discriminativa. Por esta razón, en un trabajo posterior, volvió a proponer una modificación del método para lograr la segmentación de texturas desconocidas, donde unía al LBP la característica del contraste. La distribución conjunta de los dos descriptores se llama LBP/C. El rango de valores posibles depende del número de agrupaciones de contraste que se consideren. Aunque el número de posibles valores disminuye considerablemente comparándolo con el descriptor TU, éste sigue siendo muy grande.

Prieto ha propuesto un nuevo descriptor de textura local que consiste en una simplificación de la TU llamado Simplified Texture Unit (STU). El STU toma un reducido número de valores $[0,80]$ sin una pérdida significativa de capacidad discriminativa. Las distribuciones (espectros de frecuencia) obtenidas con este método permiten tomar decisiones fiables con tamaños de regiones más pequeñas que los tamaños que se necesitarían en otros

métodos. Además la STU mejora tiene mayor exactitud en la localización de fronteras. Otra cualidad añadida es la reducción de requerimientos de memoria y de tiempo computacional en un ordenador.

- **Descriptores de textura local: de la TU a la STU**

Como explicamos anteriormente el descriptor TU toma una vecindad de 3x3 píxeles compuesta por 9 valores: un píxel central v_p y ocho píxeles vecinos v_1, \dots, v_8 . El método de la unidad de textura transforma estos píxeles vecinos en otros píxeles e_i dados por la ecuación 21.

$$e_i = \begin{cases} 0, & \text{if } v_i < (v_p - \Delta), \\ 1, & \text{if } (v_p - \Delta) \leq v_i \leq (v_p + \Delta), \\ 2, & \text{if } v_i > (v_p + \Delta), \end{cases} \quad \text{Ecuación 21}$$

Donde v_i es el valor de nivel de gris del vecino i y Δ es el parámetro de tolerancia.

El TU se representa de modo compacto con el NTU. En la figura siguiente se muestra un ejemplo de este descriptor con $\Delta=2$, donde la NTU = 1 + 3 + 18 + 243 + 2187 = 2533.

Ojala et al. propuso una simplificación en la definición del descriptor TU, llamado Local Binary Pattern (LBP). Esta simplificación lleva consigo una umbralización con sólo un valor umbral que sigue la norma (ecuación 22):

$$e_i = \begin{cases} 0, & \text{if } v_i \leq v_p, \\ 1, & \text{if } v_i > v_p. \end{cases} \quad \text{Ecuación 22}$$

El LBP puede también ser representado de modo compacto a través de la ecuación 23:

$$N_{\text{LBP}} = \sum_{i=0}^{i=7} e_i 2^i \quad \text{Ecuación 23}$$

Aunque el LBP describe la estructura espacial de la textura local, este no lo hace del mismo modo que el contraste. Por esta razón, Ojala et al usa, para llevar a cabo la segmentación de texturas desconocidas, combina el LBP con una medida del contraste local

C. El contraste local C es un descriptor que se define como la diferencia entre la media de los niveles de gris de los píxeles con $e_i = 1$ y los píxeles con $e_i = 0$. La figura c muestra como obtener el descriptor LBP asignado a un ejemplo de entorno de vecindad. El NLBP es 4 donde los pesos del LBP que se han usado se muestran en la figura d. El contraste local se $C = 131 - (128 + 127 + 125 + 126 + 128 + 124 + 127)/7 = 5$.

Para caracterizar la textura de una región, se usa la unión del LBP y del descriptor C. El LBP/C toma un conjunto de valores dado por $[0,256xb]$ donde b representa el número de valores que pueden tomar las agrupaciones de contraste. Ojala et al. ha determinado experimentalmente que el número ideal de valores de agrupaciones del contraste es $b=8$ y, por consiguiente, el tamaño mínimo de región necesario para obtener un histograma con valores de NLBP/C puede ser reducido, comparado con el descriptor TU.

Pero el tamaño de la región puede ser reducido aún más si usamos un nuevo descriptor de textura local propuesto por M. Prieto. Este nuevo descriptor se llama Simplified Textura Unit (STU). Solo cuatro valores de la TU se usan de los que se han calculado en a partir del entorno de vecindad. De este descriptor se pueden tomar dos versiones: cuando usamos los vecinos en forma de cruz (arriba, derecha, abajo e izquierda) la versión se llama STU1, cuando usamos los vecinos diagonales (arriba-derecha, arriba-izquierda, abajo-derecha, abajo-izquierda) la versión se llama STU2. De nuevo, usando la N_{STU} calculada mediante la ecuación 24, el descriptor STU se puede usar de un modo más compacto.

$$N_{STU} = \sum_{i=0}^{i=3} e_i 3^i \quad \text{Ecuación 24}$$

Si los pesos de STU1 y STU2, dados en la figura 9(d), los aplicamos al ejemplo de TU mostrado en la figura 9(b) obtenemos $N_{STU1} = 1 + 9 + 27 = 37$ y $N_{STU2} = 1 + 6 + 9 = 16$.

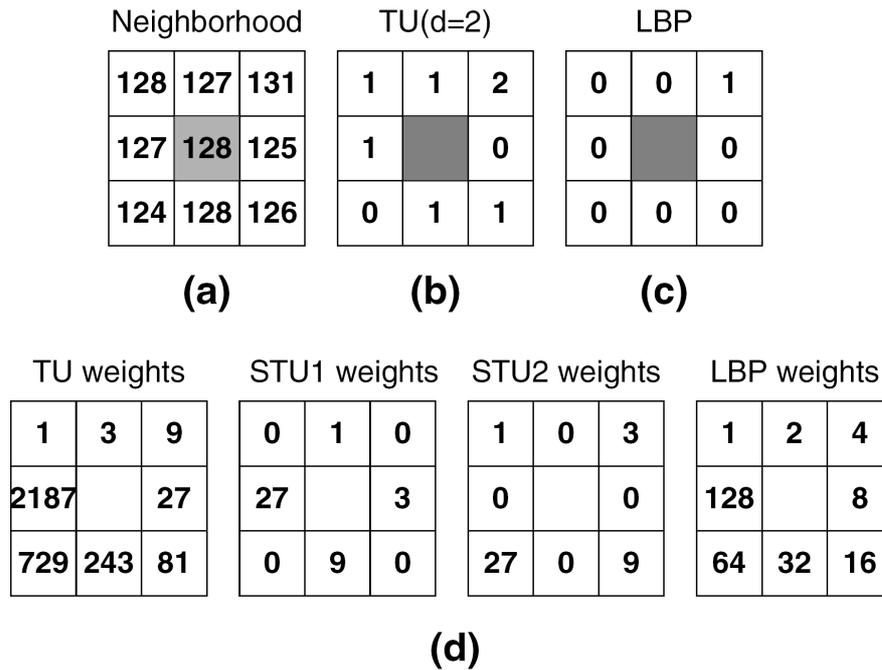


Figura 9. Un ejemplo de entorno de vecindad local (a) y los correspondientes descriptores: TU con $\Delta = 2$ (b) y LBP (c). Los pesos para obtener las NTU, NSTU1, NSTU2, y el NLBP se muestran en la figura (d).

- Experimentos y resultados de M. Prieto

Para comparar los métodos se seleccionaron 15 texturas de álbum Brodatz. Estas imágenes se trataron previamente con un filtro de la mediana con el fin de eliminar el ruido de fondo de las imágenes.

Para cada método se hizo una batería de pruebas variando diferentes parámetros. Por ejemplo, para la TU y la STU se tomaron distintos valores de Δ : 0, 2, 4, 8, 16, y 32. Para el descriptor LBP/C se tomaron distintos valores de $b = 2, 4, 8, 16$ y 32. LBP no tenía parámetros.

A la vez se tomaron muestras de las imágenes de diferentes tamaños. Siendo L el tamaño de la ventana $L \times L$ se tomaron valores $L = 4, 8, 16, 32, 64$.

El funcionamiento de cada descriptor fue evaluado a través de la tasa de error cruzado (MCR) con el clasificador de los k vecinos más cercanos (KNN). El MCR se ha obtuvo

usando validación cruzada para cada conjunto de datos. También se le dieron distintos valores al parámetro del KNN. Los valores de k tomados fueron $k = 3, 9$.

Por último se tomaron distintos métodos de medir distancias entre las distribuciones: suma de diferencias absolutas (L_1), la función de Pearson (λ) y el logaritmo de la tasa de verosimilitud ($\log\text{-lh}$).

Los resultados obtenidos de estas pruebas (Tabla 7 y figura 10) fueron los siguientes:

Descriptor	k	Measure	Parameter	Av. MCR
LBP/C	9	L_1	$b = 4$	0.0698
STU ₁	9	λ	$\Delta = 8$	0.0705
STU ₂	9	$\log\text{-lh}$	$\Delta = 32$	0.0726
TU	9	L_1	$\Delta = 16$	0.0848
LBP	9	λ	<i>n.a.</i>	0.0994

Tabla 7. Ranking de la evaluación de los descriptores usando la media MCR

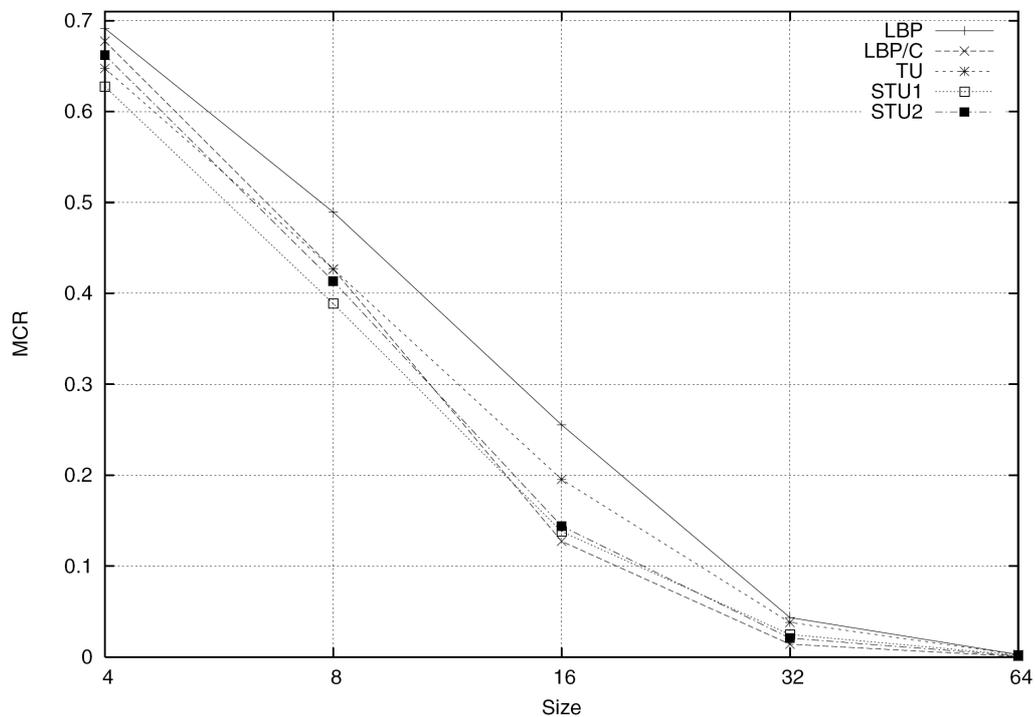


Figura 10. MCR versus tamaño de región. Para cada descriptor estudiado, se usan los parámetros de la tabla anterior

- Conclusiones de M. Prieto sobre la STU

De la media MCR mostrada en la tabla anterior (tabla 7), se puede concluir que el descriptor STU tiene un funcionamiento similar que el dado por el descriptor LBP/C. La versión STU1, que usa los vecinos en cruz, muestra un funcionamiento ligeramente mejor que la versión STU2 que usa los vecinos diagonales. Ambas versiones mejoran el funcionamiento del descriptor TU. Esto demuestra que el descriptor TU introduce redundancia en los cálculos. El descriptor LBP es el que muestra peor funcionamiento de los métodos que estudia Prieto.

Cuando se usan regiones de tamaño grande (mayores de 32x32 aproximadamente), todos los descriptores tienen una baja media MCR, con pequeñas diferencias entre ellas. Cuando se usan regiones de tamaño pequeño (menores de 16x16), el método nuevo STU tiene un funcionamiento mejor que los demás. Se puede resaltar además que mientras que el descriptor LBP/C con $b = 4$ tiene $256 \times 5 = 1024$ posibles valores, el descriptor STU tienen sólo 81 posibles valores.

También hay que señalar que, al igual que comentan Prieto y Ojala et al, no hay diferencia significativa en el método que usemos a la hora de medir distancias entre histogramas (o espectros de frecuencia). Por tanto, la mejor es la que conlleve un menor coste computacional, que sería la diferencia absoluta de histogramas L1.

Por tanto, con este apartado queda justificado el uso del descriptor STU, aun siendo más simple que el descriptor TU. La simplificación llevada a cabo no implica ninguna pérdida significativa de la capacidad de caracterización de texturas cuando se usa una región de tamaño grande. Mientras que cuando se usa una región pequeña mejora su capacidad de caracterización, con respecto a los descriptores TU, LBP/C y LBP. Este mejor funcionamiento, cuando se usan regiones pequeñas, podría significar una mejor exactitud en la localización de fronteras entre regiones texturales. También, la simplificación realizada reduce de modo significativo, los requerimientos de memoria y el coste computacional.

2.4. Distancias

Hasta ahora hemos presentado los distintos métodos que vamos a estudiar para aplicarlos al caso de imágenes con textura de humo. Los métodos que hemos presentado son el método estadístico de primer orden basado en el histograma, donde teníamos la opción de hallarlo a color o en blanco y negro; el método de la matriz de coocurrencia, donde también tenemos la opción de hallarla para imágenes en blanco y negro o en color, por último el nuevo método propuesto por M. Prieto que es como el resultado del recorrido que ha ido siguiendo el popular método de unidad de textura TU que propuso He and Li Wang en 1990.

Para cada uno de los métodos obtenemos varias salidas, es decir, unos resultados que se pueden medir entre ellos, y que determinan el resultado de la clasificación. Así, ponemos a continuación los tipos de resultados que se obtienen de cada método.

Histograma en B&N	{	- Descriptores : media, desviación estándar, tercer momento y entropía
	}	- Histograma de los niveles de gris
Histograma en color	{	- Descriptores : media, desviación estándar, tercer momento y entropía
	}	- Histograma enlazado de los tres colores RGB
M. de Coocurrencia en B&N	{	- Descriptores : energía, entropía, contraste, homogeneidad y correlación
	}	- Histograma (con direcciones de búsqueda)
M. de Coocurrencia en color	{	- Descriptores : energía, entropía, contraste, homogeneidad y correlación
	}	- Histograma (con direcciones de búsqueda y color)
Unidad simplificada de textura (STU)	{	Histograma o espectro de frecuencia

2.4.1. L2 sobre estadísticos

Tanto en el método del histograma como en el método de la matriz de coocurrencia podemos hallar unos descriptores de textura a partir del histograma en el primer caso o a partir de la matriz de coocurrencia en el segundo.

Una vez que calculamos estos descriptores tenemos un vector que contiene el valor de cada uno de los descriptores que hemos hallado.

Aunque existen múltiples formas de tener una medida de la distancia entre vectores en nuestro trabajo hemos aplicado el método de distancia L2 para medir las distancias entre vectores de descriptores.

La medida L2 consiste en calcular la distancia cuadrática de un vector a otro (ecuación 25). Esto se calcula hallando la raíz cuadrada de la diferencia de los elementos de los vectores al cuadrado, es decir, si tenemos dos vectores del mismo tamaño S y M:

$$D_{L2} = \sqrt{\sum_i (S_i - M_i)^2}$$

Ecuación 25

2.4.2. Comparación de distribuciones

Tanto en el método del histograma, como en el de la matriz de coocurrencia, como en el de la STU obtenemos como salida una distribución de valores. En el caso del histograma obtenemos un histograma, en el caso de la matriz de coocurrencia obtenemos una distribución donde en el eje de abscisas representamos todos los valores que puede tomar la matriz de coocurrencia sin normalizar y en el eje de ordenadas representamos la frecuencia de repetición de los valores de la matriz. Y en el caso de la STU obtenemos un espectro de frecuencia donde en el eje de abscisas tenemos los 34 valores que puede tomar la NSTU y en el eje de ordenadas representamos de nuevo el número de veces que se repite cada valor NSTU.

En la Tabla 8 se explican otras medidas que se han utilizado para medir la distancia entre distribuciones. Principalmente se han usado las siguientes medidas de distancia:

Método	Distancia utilizada
Histograma en B&N	Chi – cuadrado
Histograma en color	L1
M. de coocurrencia en B&N	L2
M. de coocurrencia en color	L2
STU	Intersección de histogramas

Tabla 8

a. Función Chi-cuadrado

La función chi-cuadrado es un método estándar para medir diferencias entre distribuciones del mismo tamaño. Sean S y M dos histogramas, donde S_i y M_i son el valor del elemento i para los histogramas S y M, respectivamente. Entonces la función chi-cuadrado es:

$$X^2 = \sum_{i=1}^N \frac{(S_i - M_i)^2}{S_i + M_i}$$

Ecuación 26

b. Diferencia de histogramas L1

La medida de distancia L1 es la más sencilla, y muy eficaz a la hora de tomar la distancia entre dos distribuciones. Para aplicar esta distancia los histogramas deben estar normalizados, es decir la suma de todos los valores debe ser igual a 1. Consiste en calcular la suma de los valores absolutos de la diferencia entre los vectores. Si tenemos dos histogramas S y M la distancia L1 entre ellos es:

$$L_1 = \sum_i (S_i - M_i)$$

Ecuación 27

c. Distancia cuadrática L2

La distancia cuadrática L2 aunque es algo más complicada que la L1 no siempre da mejores resultados, aunque en algunos casos sí mejora la distancia L1. Para aplicar este método los histogramas deben estar normalizados en energía. Esto quiere decir que si tenemos dos histogramas S y M, se debe cumplir que:

$$\sqrt{\sum_i S_i^2} = 1 \quad \sqrt{\sum_i M_i^2} = 1$$

Ecuaciones 28 y 29

Entonces, la distancia cuadrática entre estas dos distribuciones es:

$$L_2 = \sqrt{\sum_i (S_i - M_i)^2}$$

Ecuación 30

d. Intersección de histogramas

Swain y Ballard introdujeron una función muy simple llamada intersección de histogramas para medir la similitud entre cubos de colores. La intersección de histogramas se define como:

$$HIS = 1 - \sum_{i=1}^N \min(S_i, M_i)$$

Ecuación 31

En otras palabras, HIS mide el volumen común de los histogramas, el cual es restado a 1, obteniendo que sea igual a 0 en el caso en el que los histogramas S y M sean idénticos. Hay que notar que si el escalado de los histogramas es el mismo, así como el tamaño de los mismos, entonces la intersección de histogramas es equivalente a la suma escalada de las diferencias absolutas, que He and Wang usan para medir la similitud de los espectros de textura, al igual que nosotros lo usamos en otros casos.

3. Software para la comparación de algoritmos

3.1. Funcionamiento del programa

Quitando todos los programas de prueba que se han ido elaborando —tales como programas de ecualización, de generación de imágenes según los descriptores, etc. — el trabajo consta de dos programas principales, doce subrutinas y un programa para realizar baterías de pruebas. Vamos a comentar los dos programas principales y las subrutinas asociadas a cada uno de ellos.

- “creaDB.m”

El primer programa principal es “creaDB.m” que se encarga de crear la base de datos a partir de las imágenes de muestra que se encuentran en unas determinadas carpetas nombradas de modos concretos.

Este programa recibe de entrada imágenes en formato .jpg o .bmp, y obtiene como salida unos archivos en formato Matlab que serán datos de entrada para la otra función principal “MCR.m” (figura 11).

En este programa en particular, hay que especificar si es .jpg o .bmp en el código, en el lugar donde se forma el nombre del archivo, pero todas nuestras imágenes de entrada están en formato mapa de bits, pues es como se obtuvieron directamente de las quemas de Gestosa.

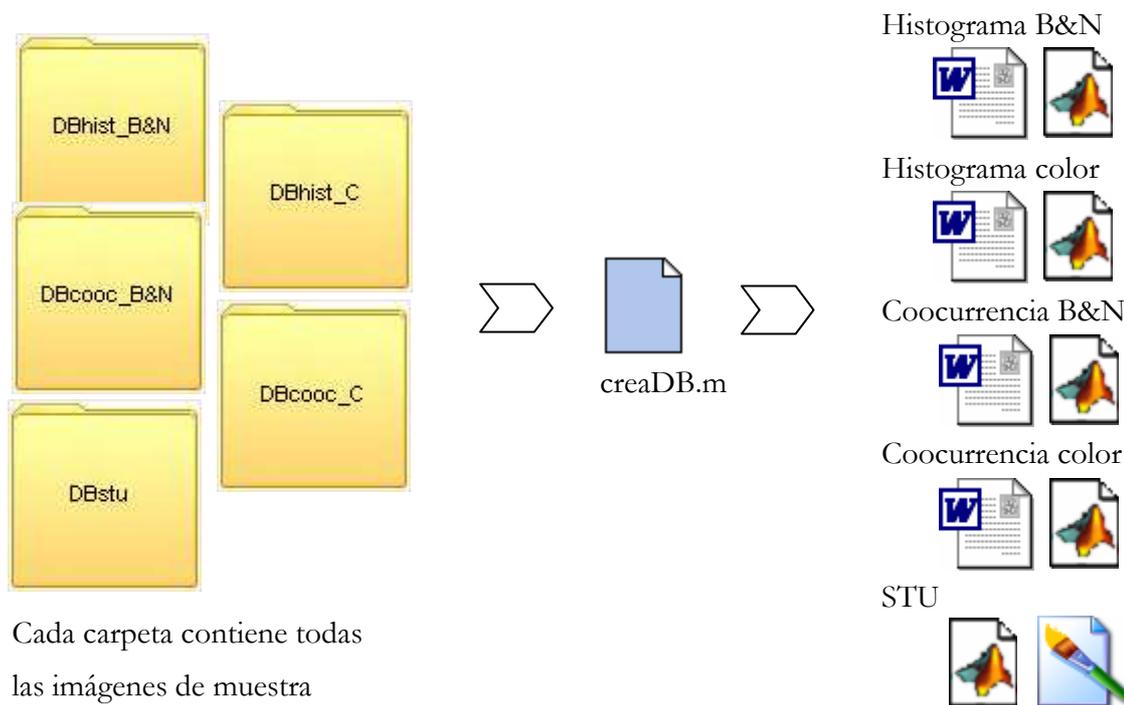


Figura 11. Esquema representativo del funcionamiento del programa "creaDB.m"

El programa "creaDB.m" llama a una serie de subprogramas durante la ejecución (figura 12). Cada subprograma se utiliza en bucles, ya sea en el mismo programa o en otros que veremos a más adelante.

Árbol de subprogramas:

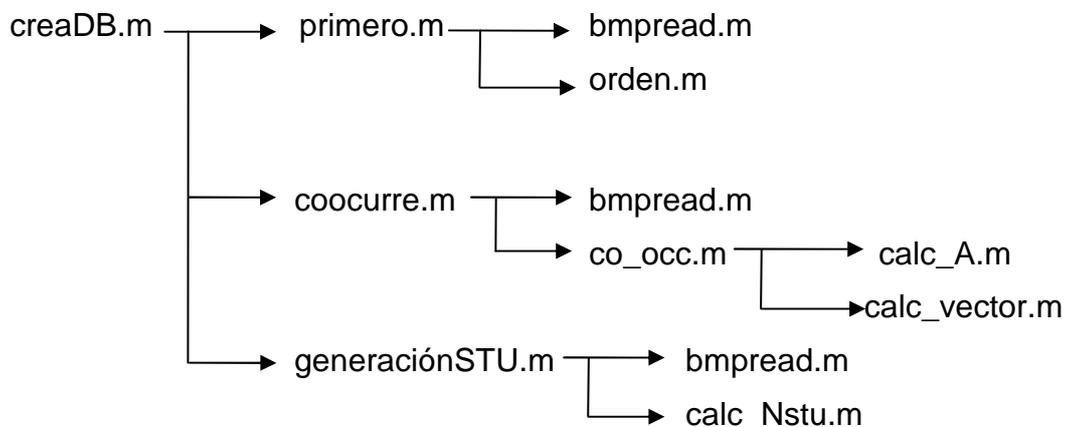


Figura 12. Árbol de programas de "creaDB.m"

En las siguientes páginas se van a presentar los diagramas de flujo de los dos programas principales: “creaDB.m” y “MCR.m”. Estos diagramas de flujo están presentados de forma básica, no entran a niveles bajos de programación, pues para un estudio más riguroso de la programación de cada método se puede hacer uso de los códigos. Con los diagramas se puede observar la estructura de funcionamiento del programa, para hacerse una idea aproximada de cómo se ha llevado a cabo la implementación de los métodos. Tanto el programa que crea la base de datos de imágenes, como el programa que carga la base de datos y hace el estudio comparativo de los programas, leen de archivos de entrada que anteriormente se han almacenado en unas carpetas cuya dirección está determinada en el código de programa y que se puede ver en la figura 12.

El programa principal “creaDB.m” (figura 14) llama secuencialmente a los programas “primero.m” y “coocurre.m” y “generacionSTU.m”, que son los subprogramas que obtienen los datos de los distintos métodos para cada una de las muestras que están guardadas en cada una de las carpetas que aparecen arriba.

El programa “primero.m” (figura 15) lee la imagen de muestra mediante la función “bmpread.m” que lo único que hace es convertir la imagen en una matriz de datos y toma de la matriz sólo las filas pares pues, la imagen está entrelazada en las filas, por tanto si cogemos todas las filas habrá información confusa en la textura ya que en realidad son dos imágenes superpuestas distintas. Después según si vamos a usar el método del histograma en color o en blanco y negro el programa realizará un bucle para el número de colores que haya. El programa “orden.m” calcula los descriptores a partir de los histogramas.

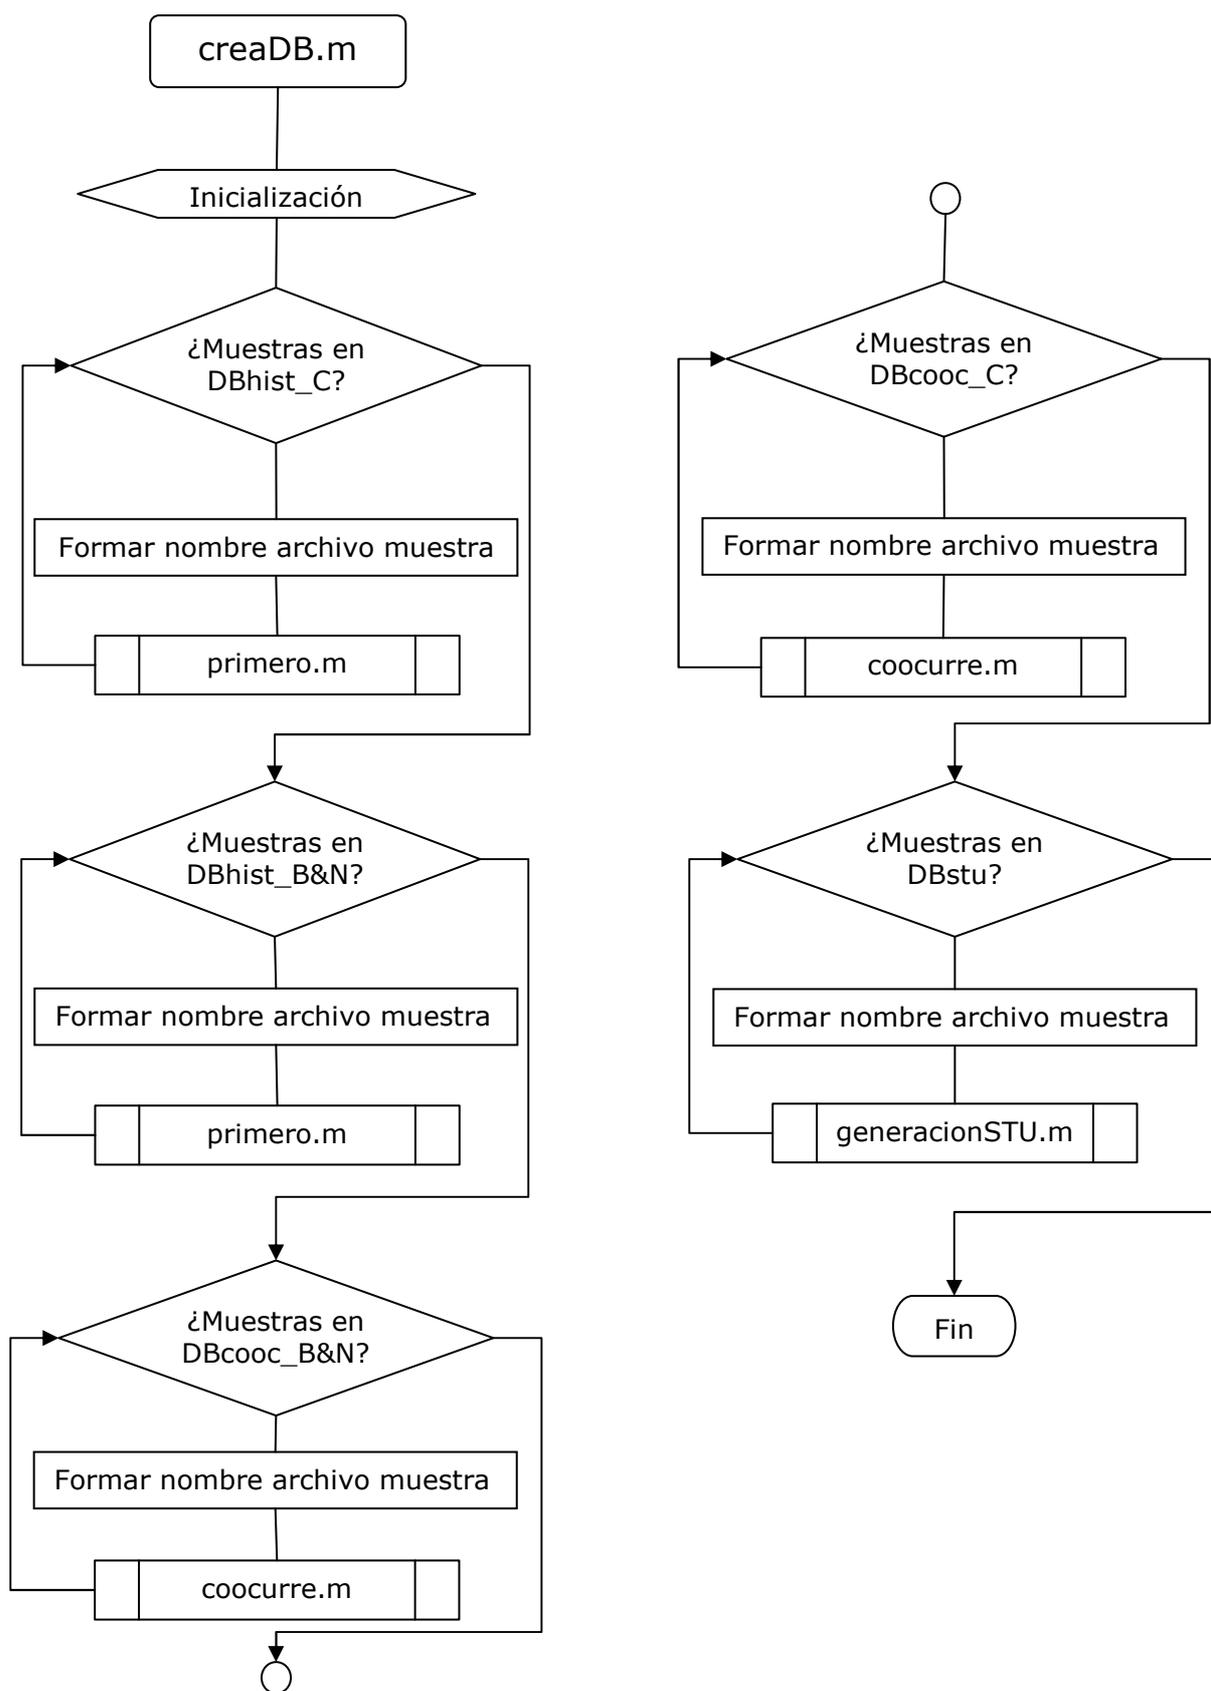


Figura 13. Diagrama de flujo de la función “creaDB.m”

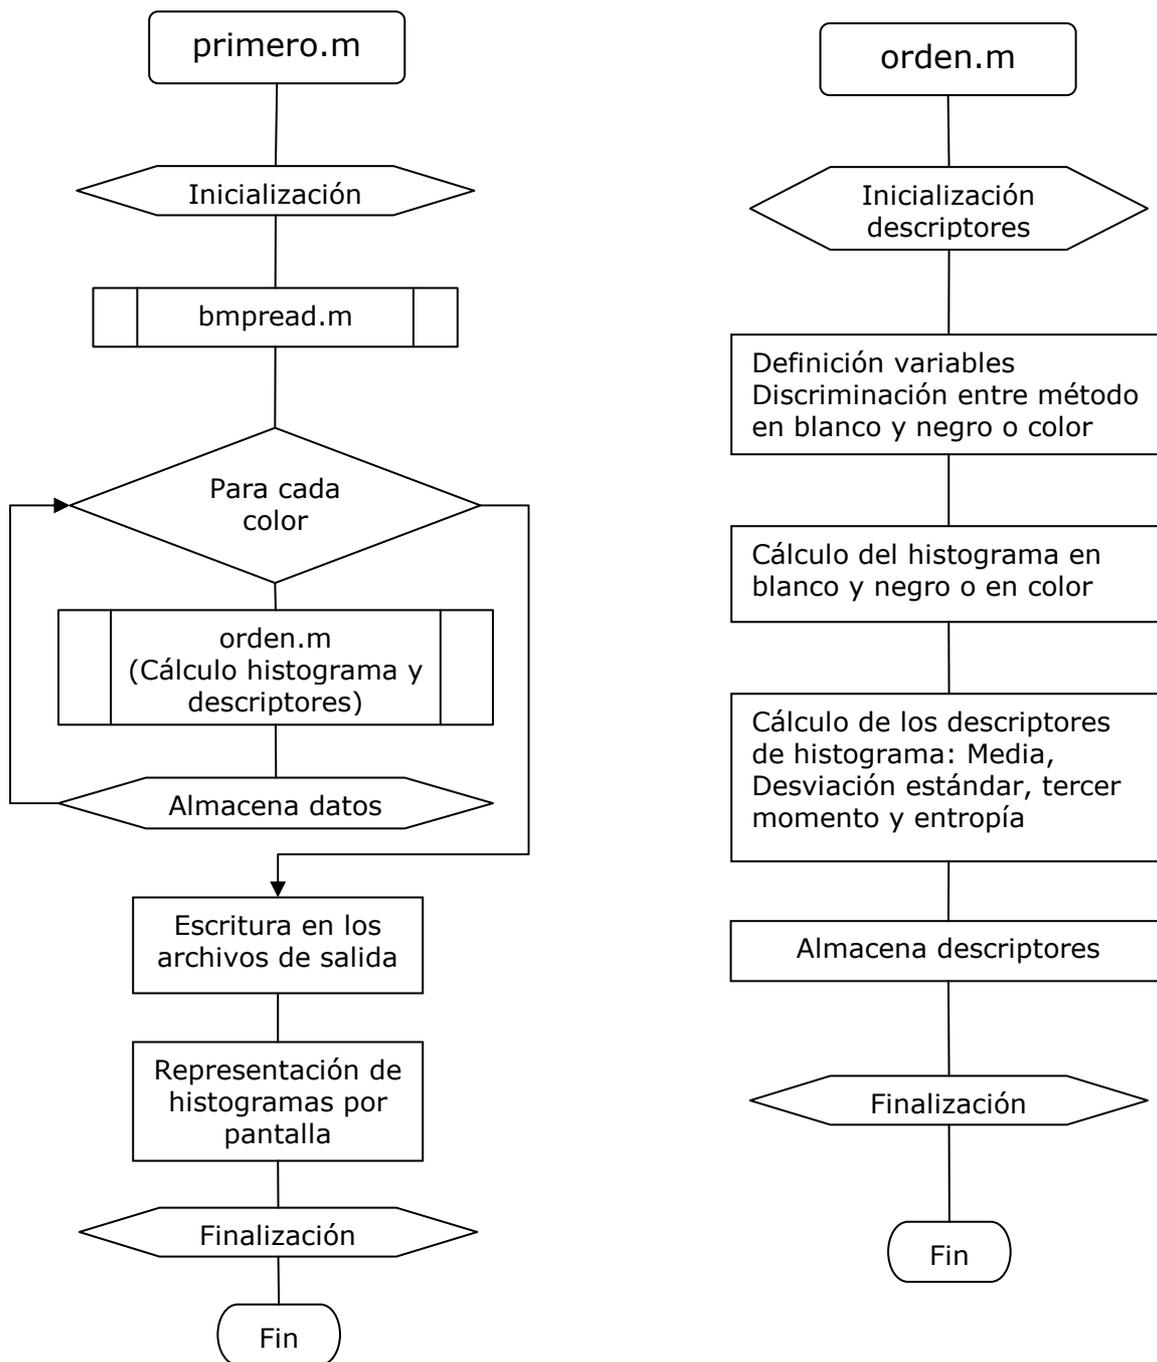


Figura 14. Diagrama de flujo de las funciones “primero.m” y “orden.m”

El programa “coocurre.m” (figura 16), al igual que el anterior calcula para cada color la matriz de coocurrencia. Si lo hacemos en blanco y negro sólo calculará una matriz, en cambio, si usamos el método a color, entonces calculará tres matrices, una para cada una de las capas

de color de la imagen. Al igual que se obtienen distintas matrices para cada una de las capas de color, también se obtienen matrices para cada una de las direcciones de búsqueda posibles. Se pueden tomar varias direcciones de búsqueda: hacia arriba, hacia la derecha, y en las dos diagonales izquierda superior y derecha superior. El programa toma las direcciones en los dos sentidos, por ejemplo, si calculo la matriz con dirección arriba, calculará también hacia abajo. Igualmente derecha-izquierda, diagonal superior izquierda-diagonal inferior derecha y diagonal superior derecha-diagonal inferior izquierda.

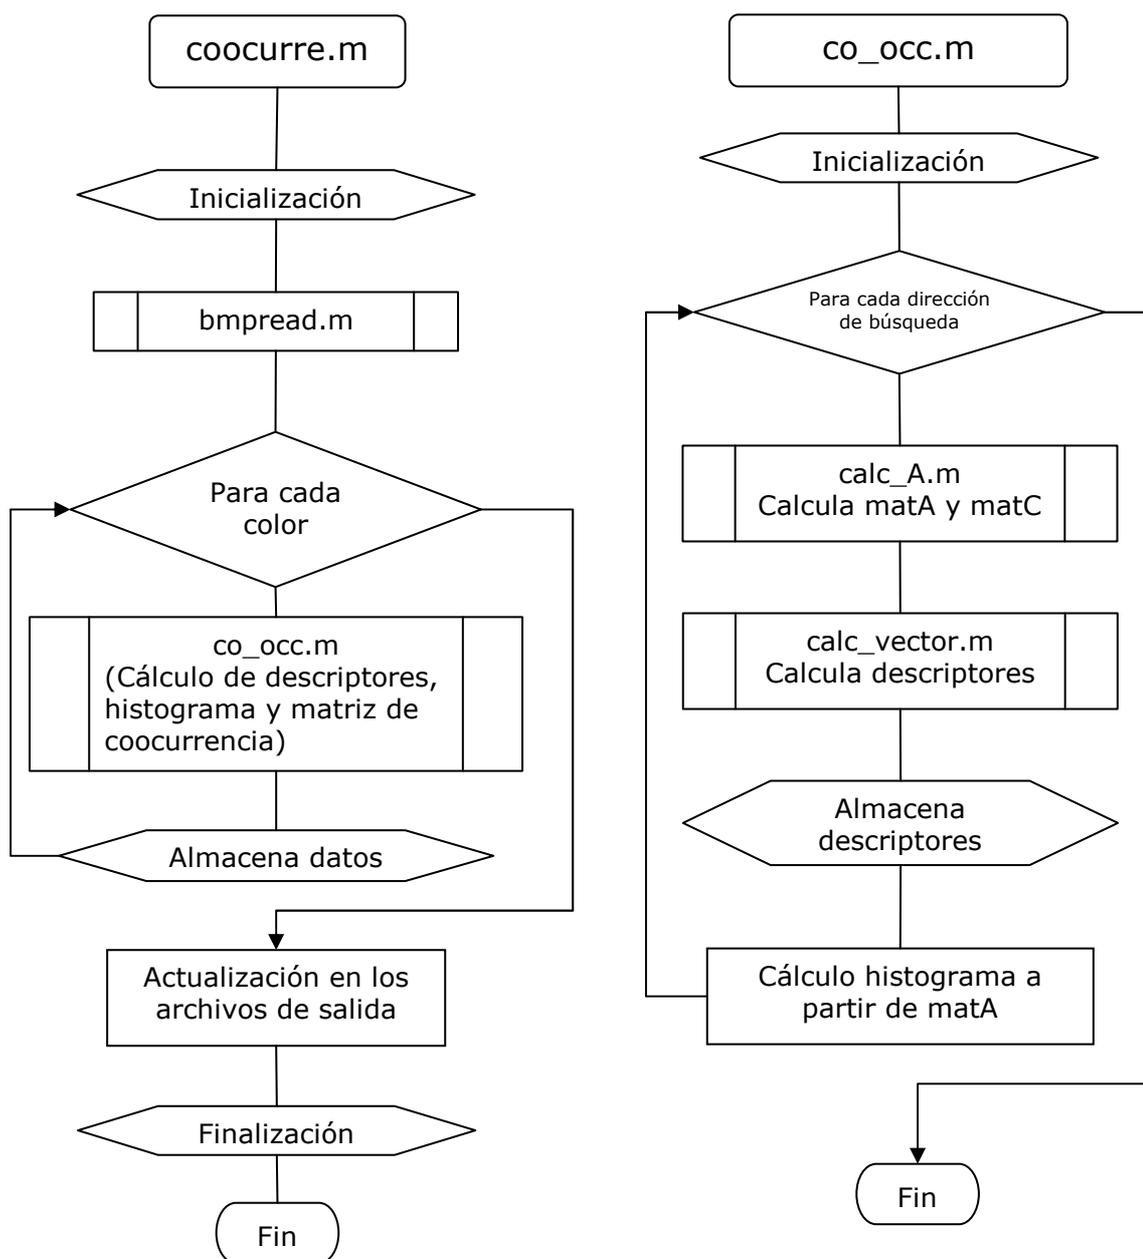


Figura 15. Diagrama de flujo de las funciones “coocurre.m” y “co_occ.m”

“calc_A.m” calcula, según la dirección de búsqueda, la matriz A que es la matriz de coocurrencia sin normalizar. Se puede observar también en la figura 17 que “calc_vector.m” calcula los descriptores de textura a partir de la matriz de coocurrencia mat_C normalizada.

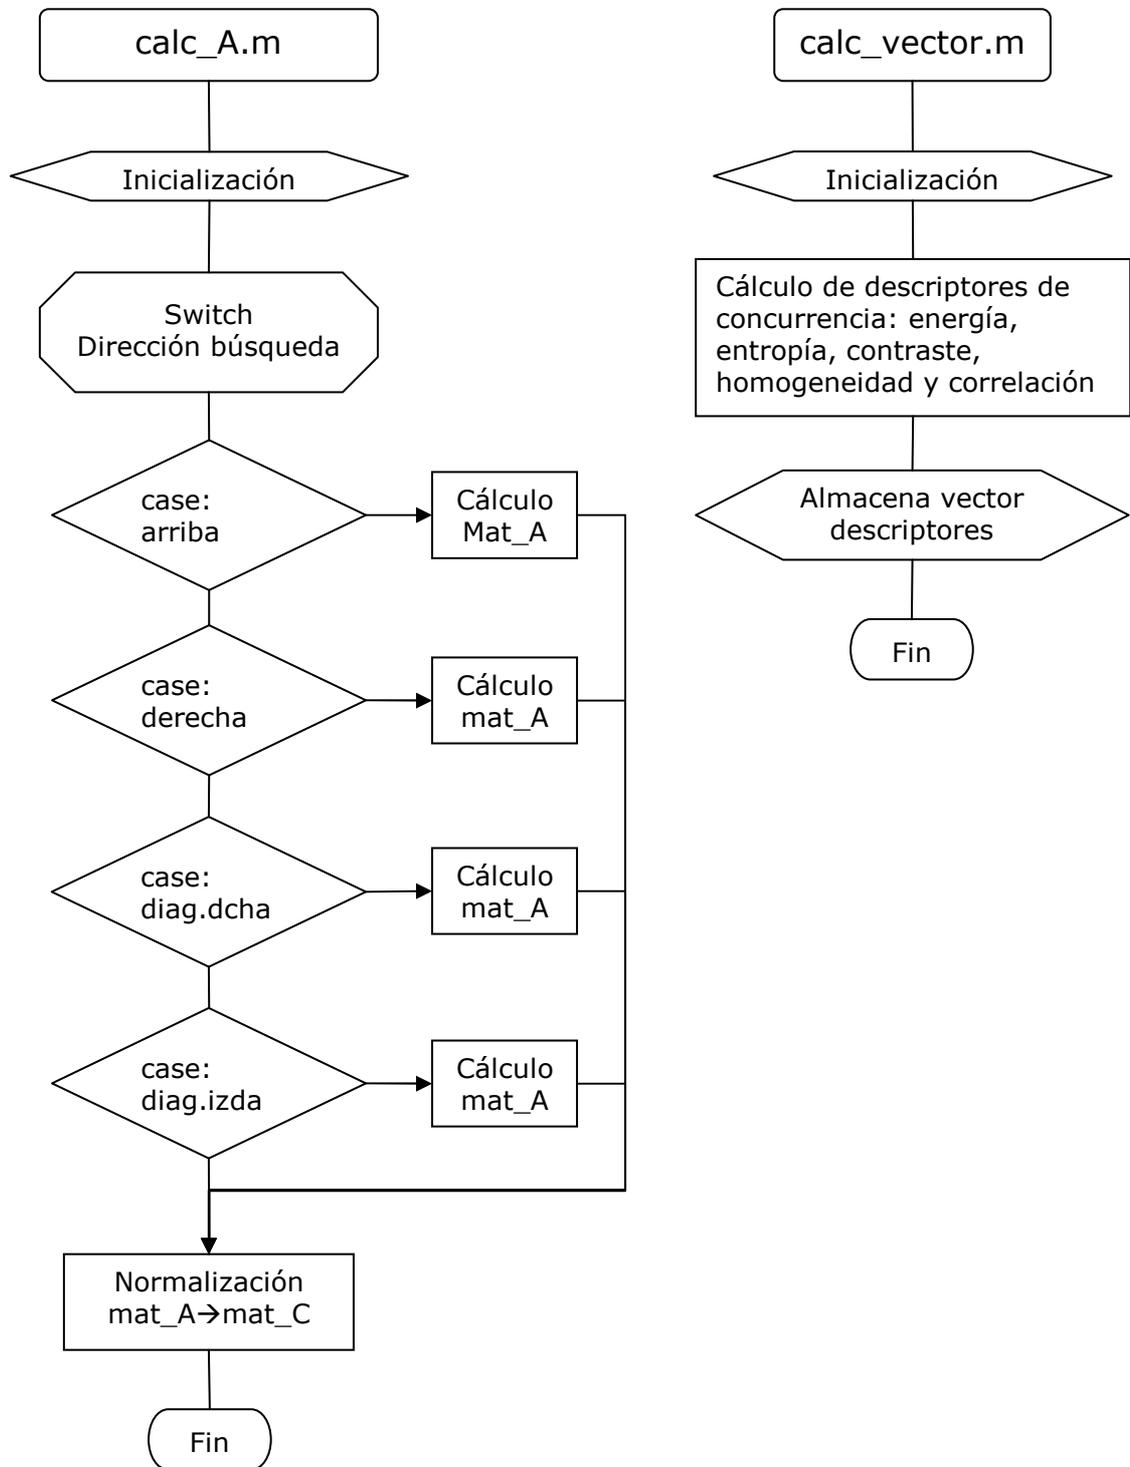


Figura 16. Diagramas de flujo de las funciones “calc_A.m” y “calc_vector.m”

Por último, la base de datos usa de la función “generacionSTU.m” (figura18) para calcular el espectro de textura de la imagen que se le para en la entrada. Con una ventana 3x3 se va recorriendo toda la imagen, y se van calculando los valores correspondientes a las ventanas de unidad de textura simplificada, y calculándose posteriormente, para cada ventana de la imagen su número de unidad de textura simplificada Nstu. Se almacenan dos tipos de archivos. Un archivo .m donde se almacena la matriz de valores Nstu y otro archivo que se actualiza si ya existe en el directorio que contiene los histogramas de todas las muestras que se le han ido pasando al histograma.

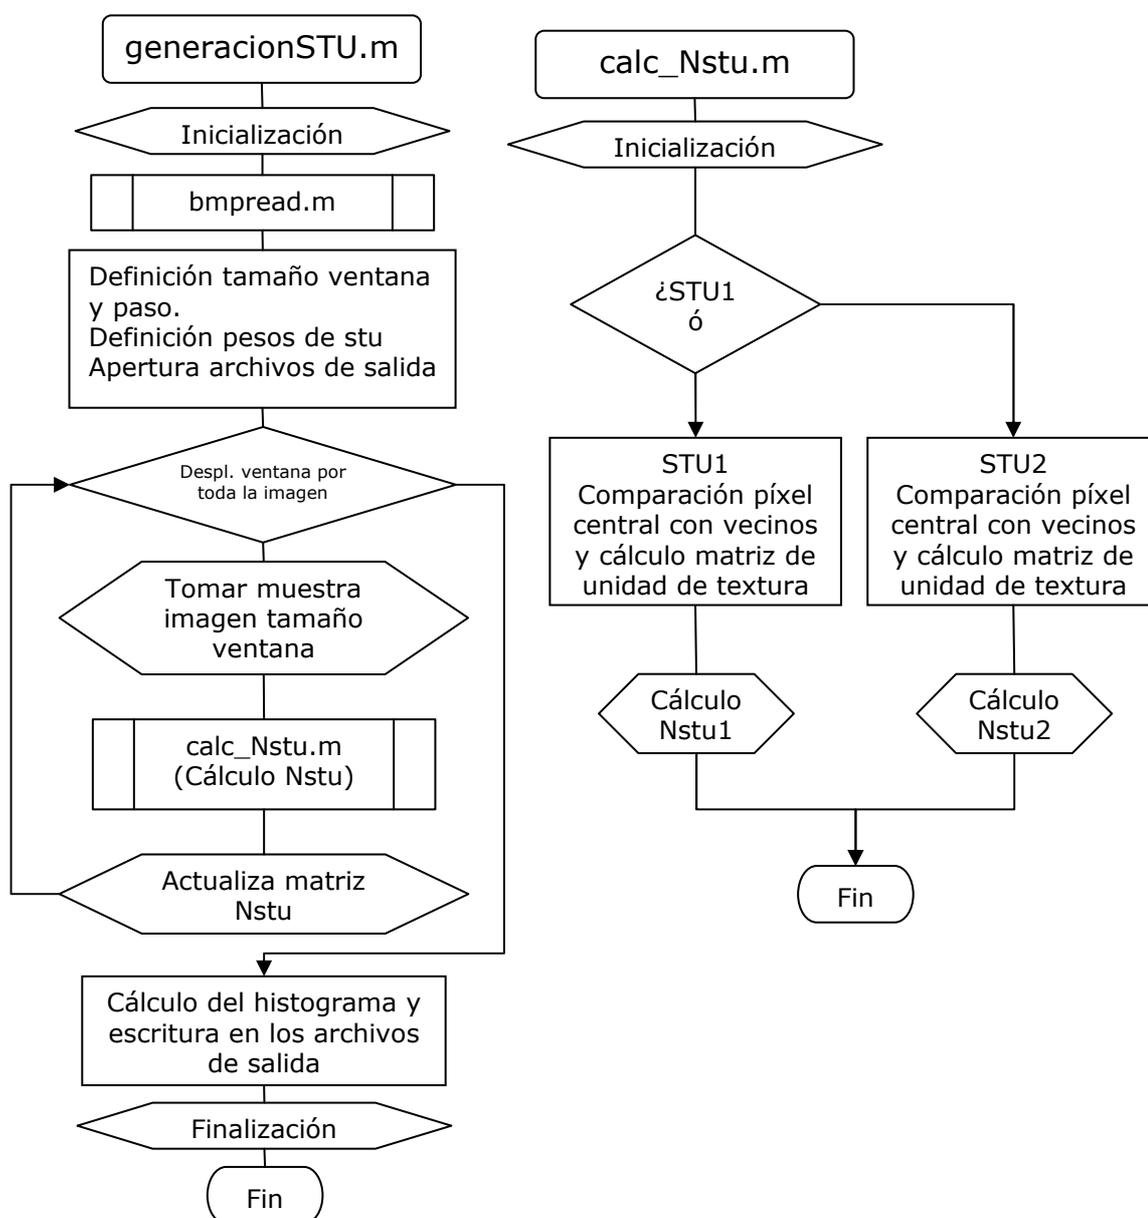


Figura 17. Diagramas de flujo de las funciones “generacionSTU.m” y “calc_Nstu.m”

- “MCR.m”

El segundo programa principal es “MCR.m” que carga la base de datos en memoria y para cualquier imagen de cualquier tamaño que se le meta en la entrada da como salida una segmentación automática de la imagen que discrimina qué zonas de la imagen pertenecen a la primera clase de textura (humo) y qué zonas pertenecen a la segunda (no humo).

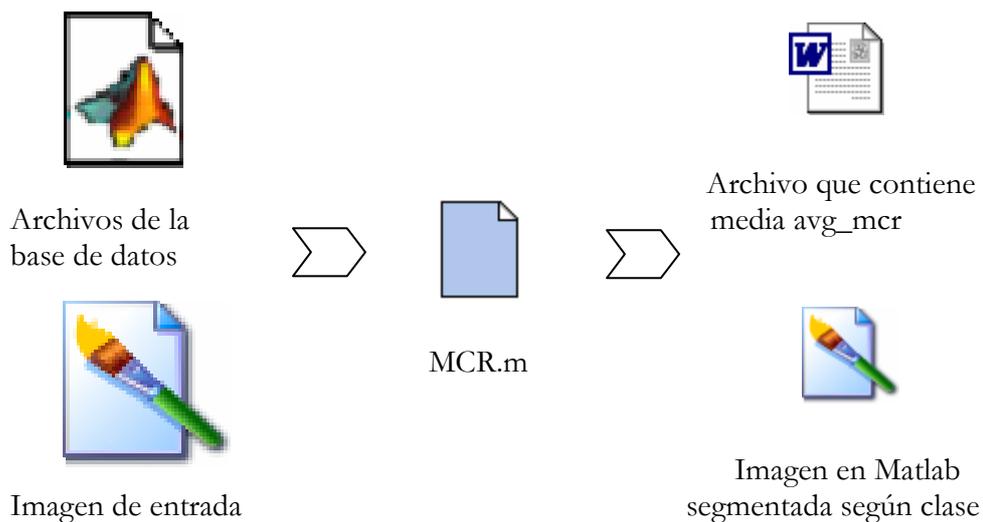


Figura 18. Esquema representativo del funcionamiento del programa “MCR.m”

El programa “MCR.m” (figura 21 y siguientes) llama a una serie de subprogramas durante la ejecución. A continuación vamos a ver cada diagrama de flujo.

Árbol de subprogramas de “MCR.m”:

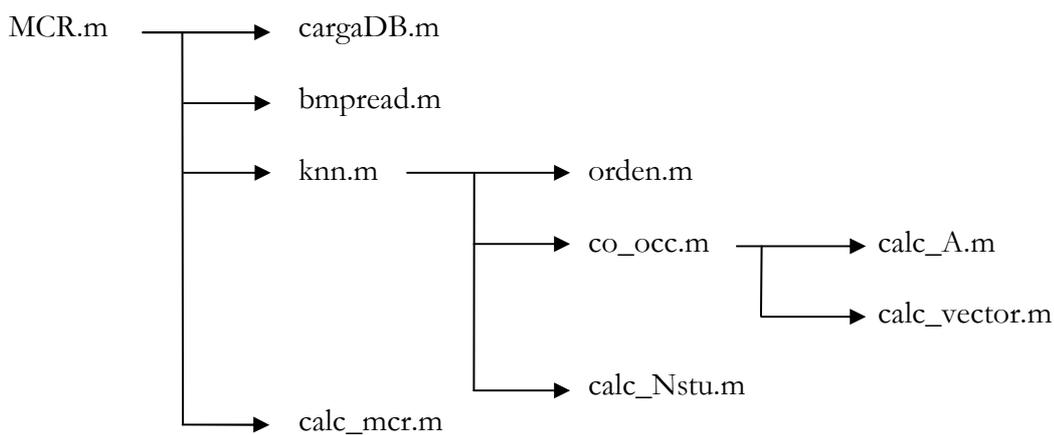


Figura 19. Árbol de programas de “creaDB.m”

A continuación vamos a comentar los diagramas de flujo de los programas MCR.m, cargaDB.m, bmpread.m, knn.m y calc_mcr.m que antes no se han comentado.

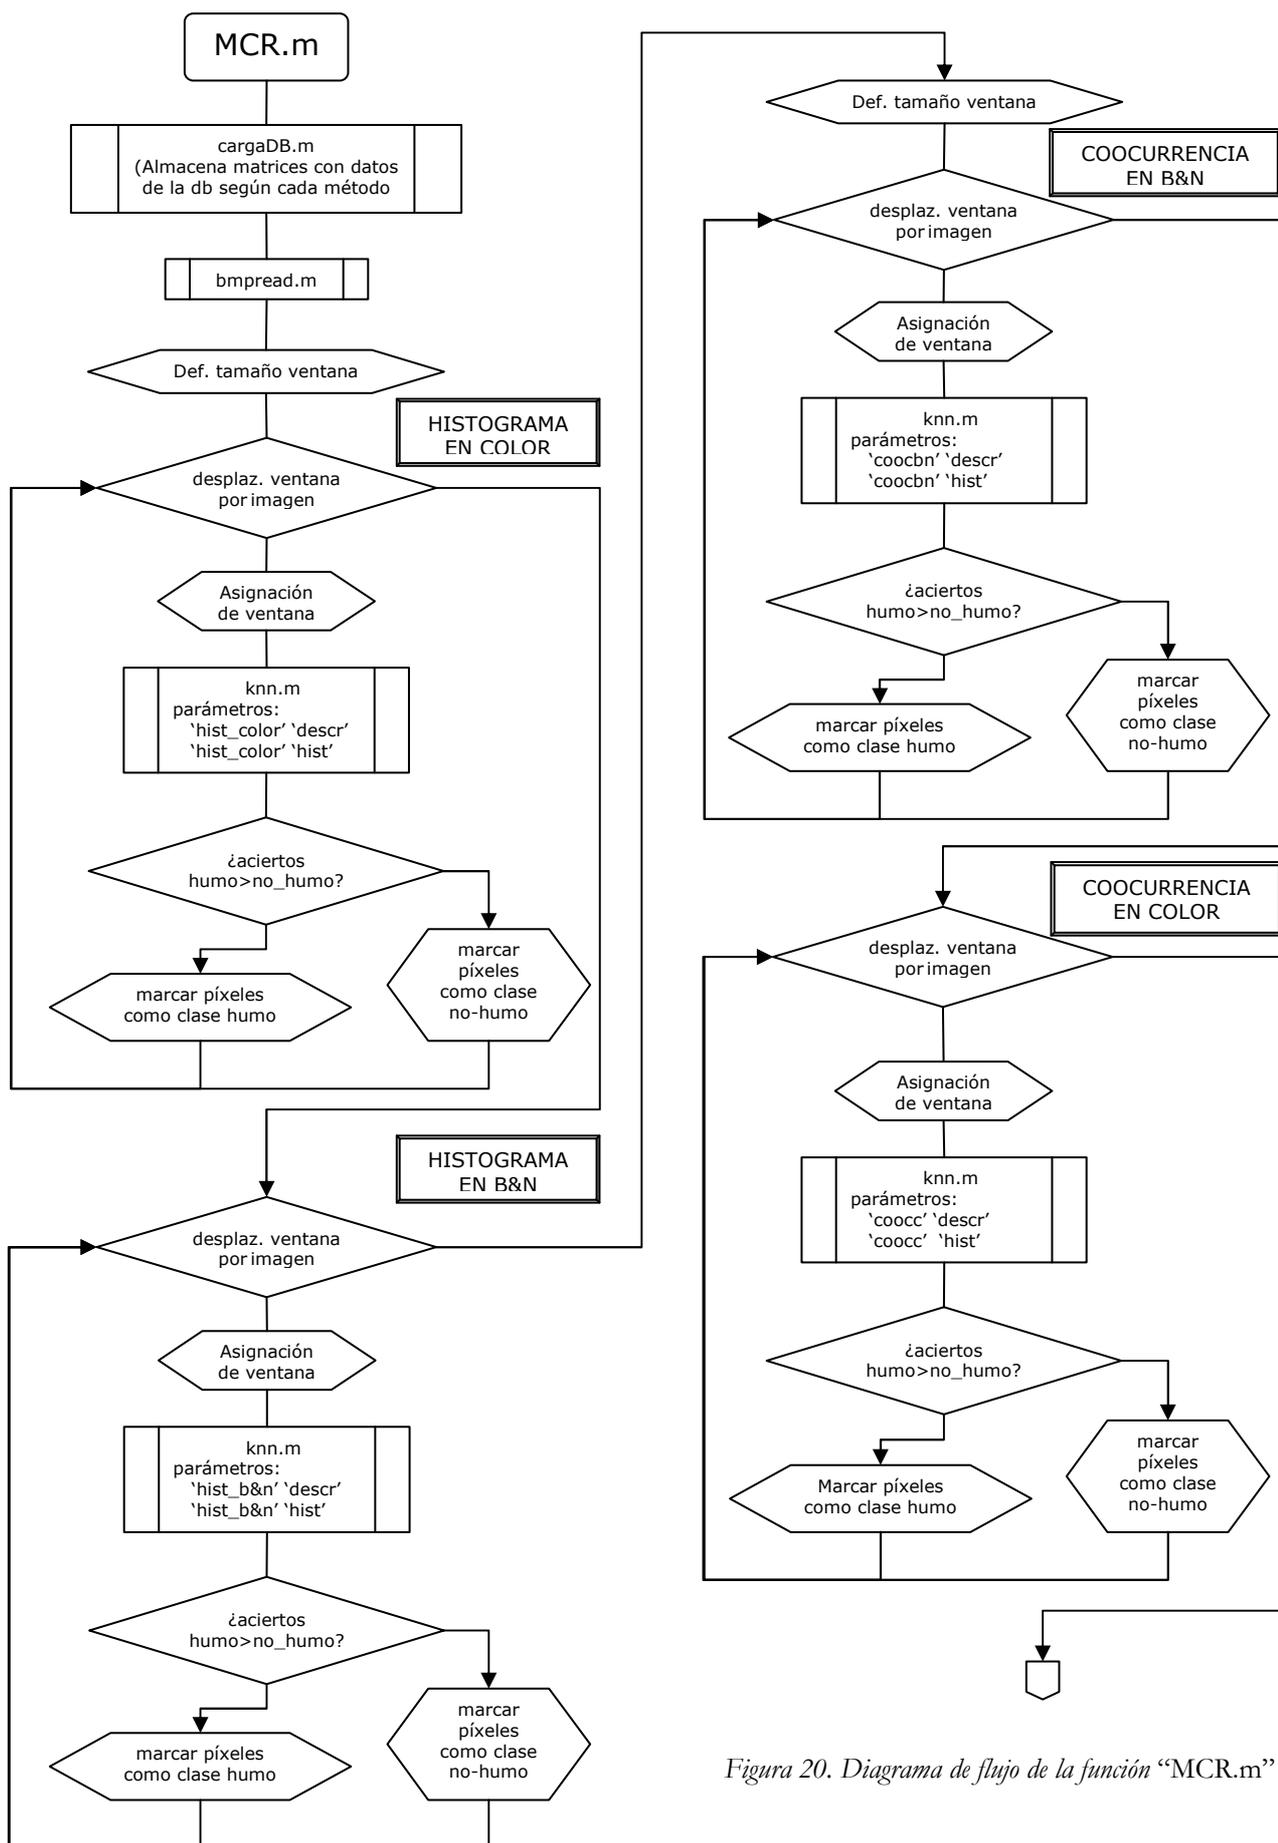


Figura 20. Diagrama de flujo de la función “MCR.m”

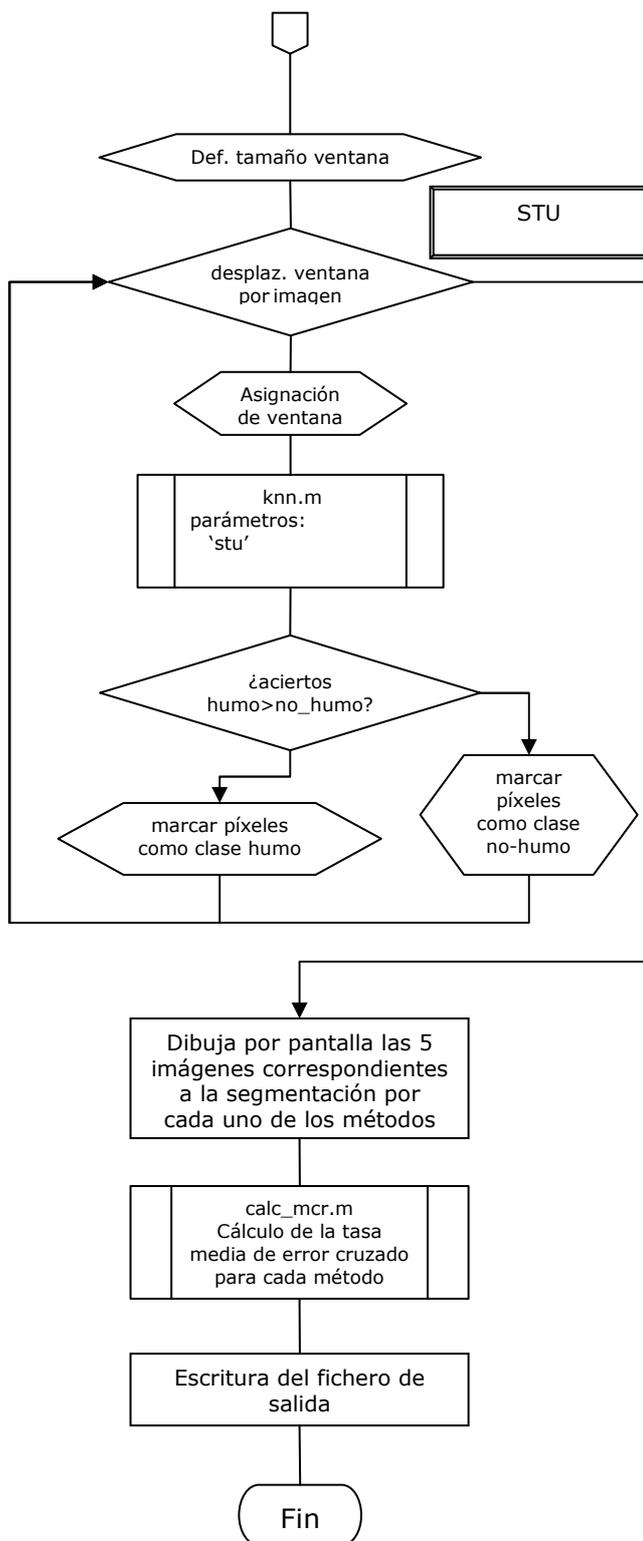


Figura 21. Diagrama de flujo de la función “MCR.m”

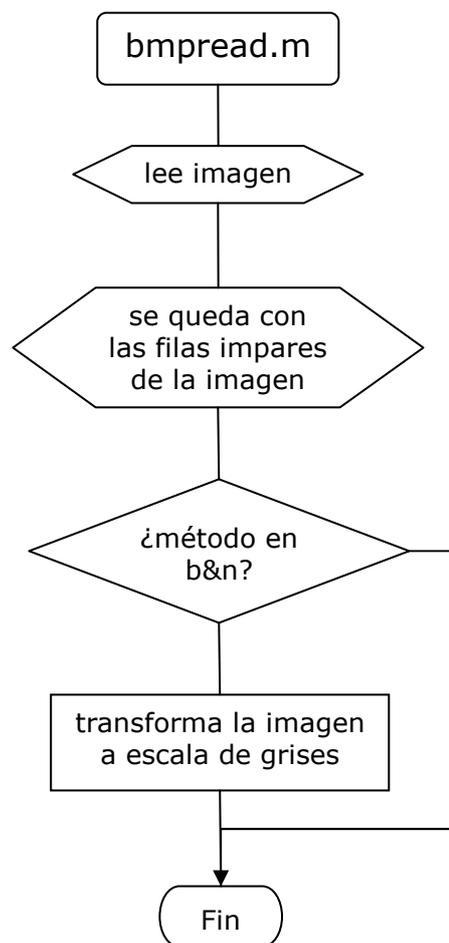


Figura 22. Diagrama de flujo de “bmpread.m”

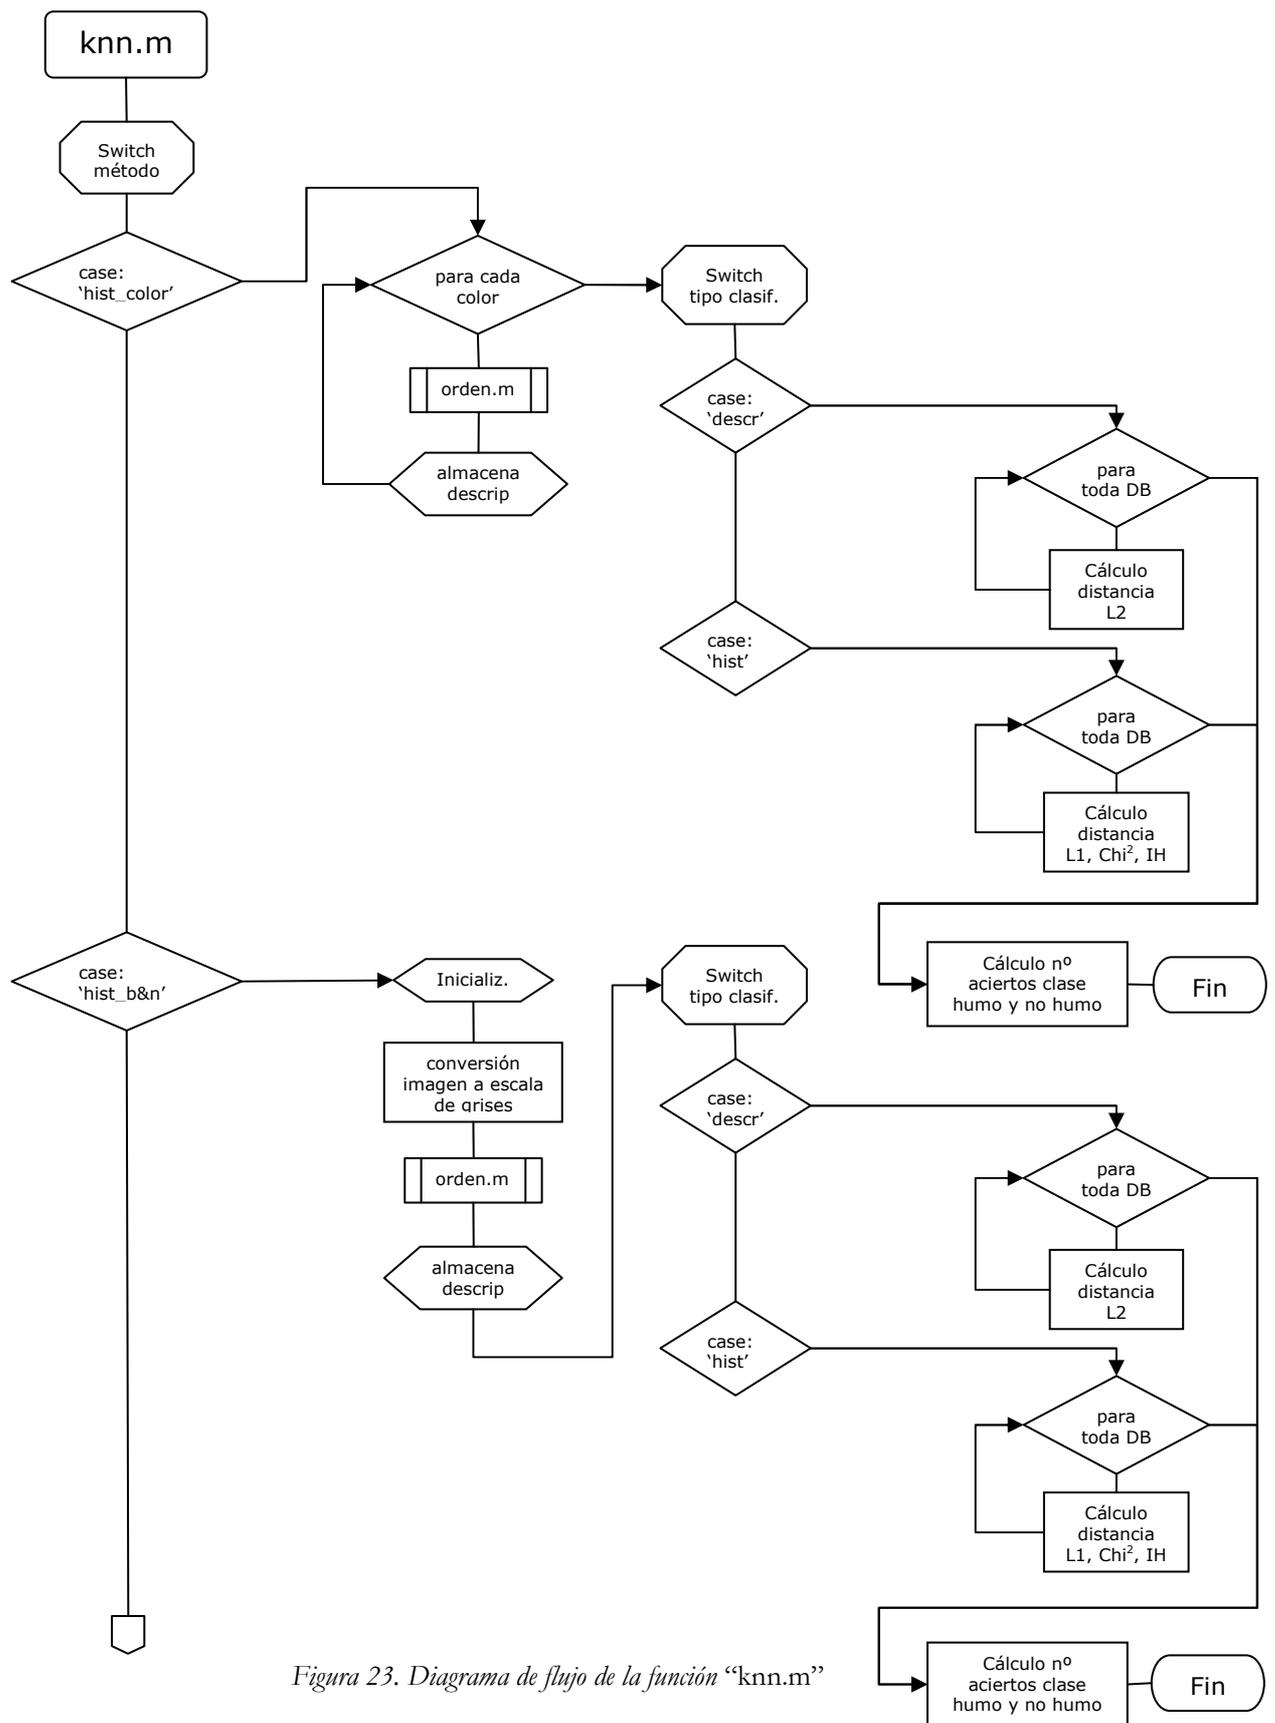


Figura 23. Diagrama de flujo de la función “knn.m”

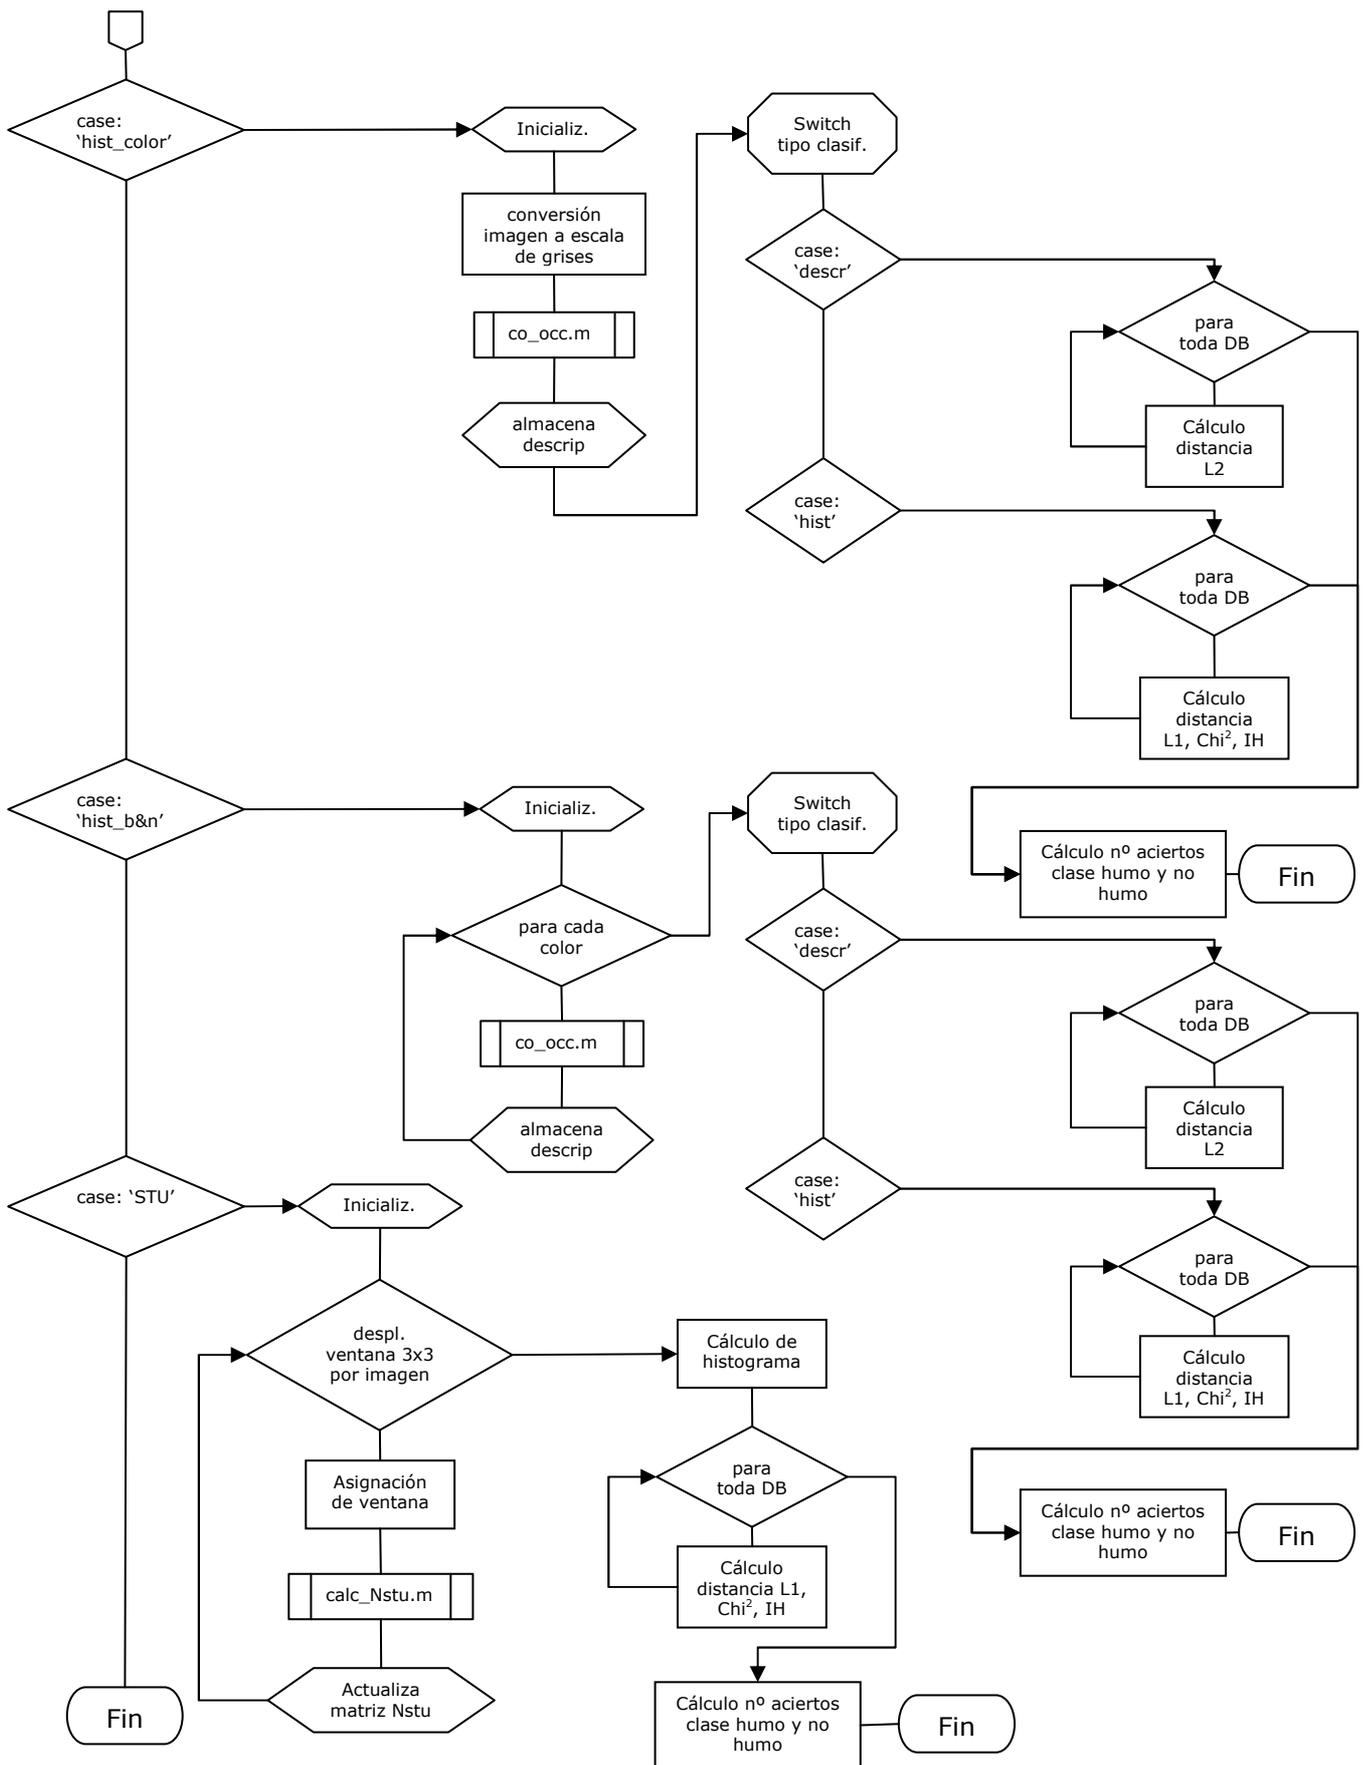


Figura 24. Diagrama de flujo de la función "knn.m"

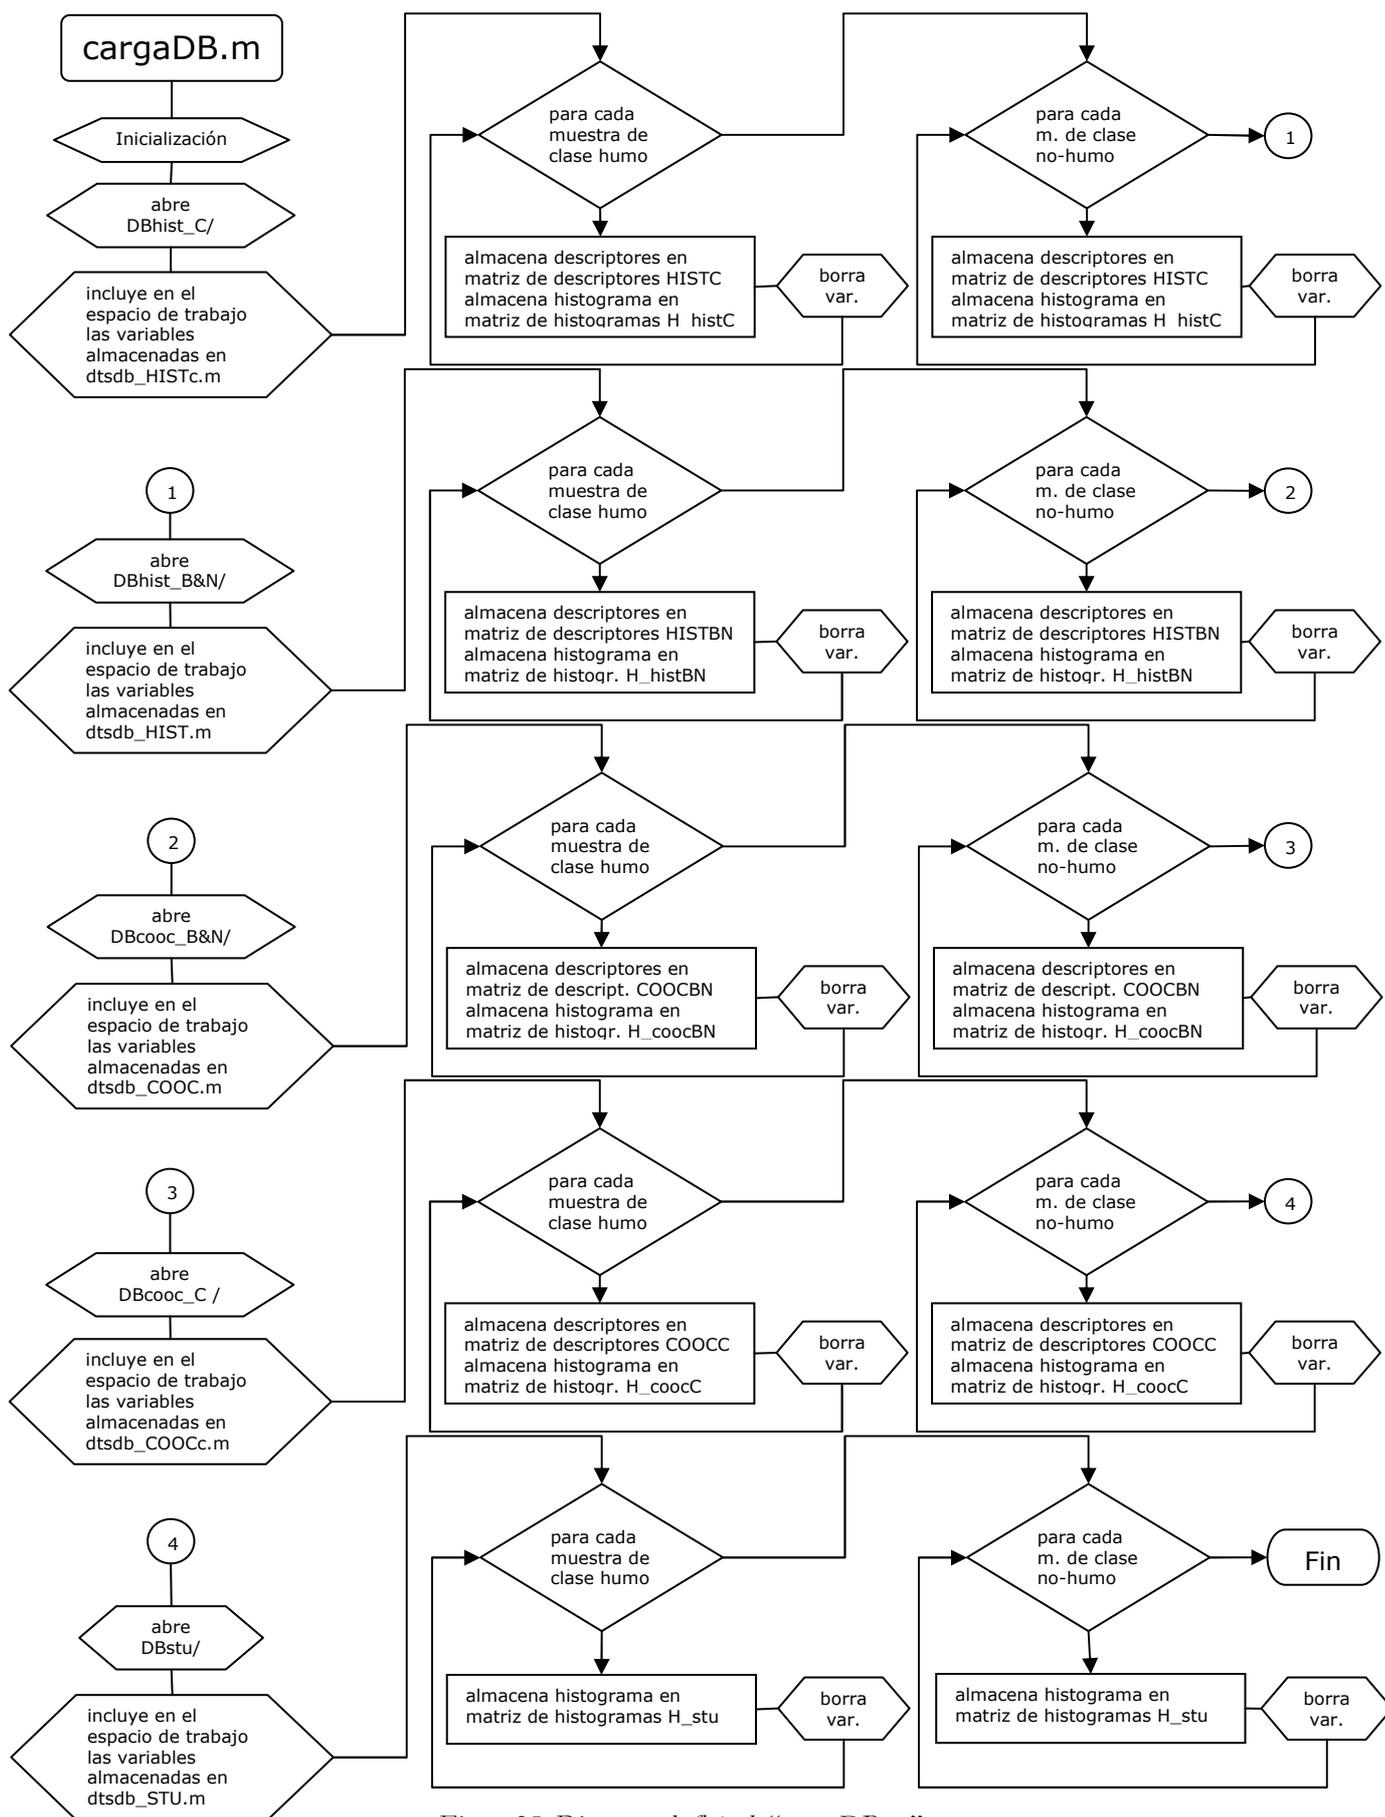


Figura 25. Diagrama de flujo de “cargaDB.m”

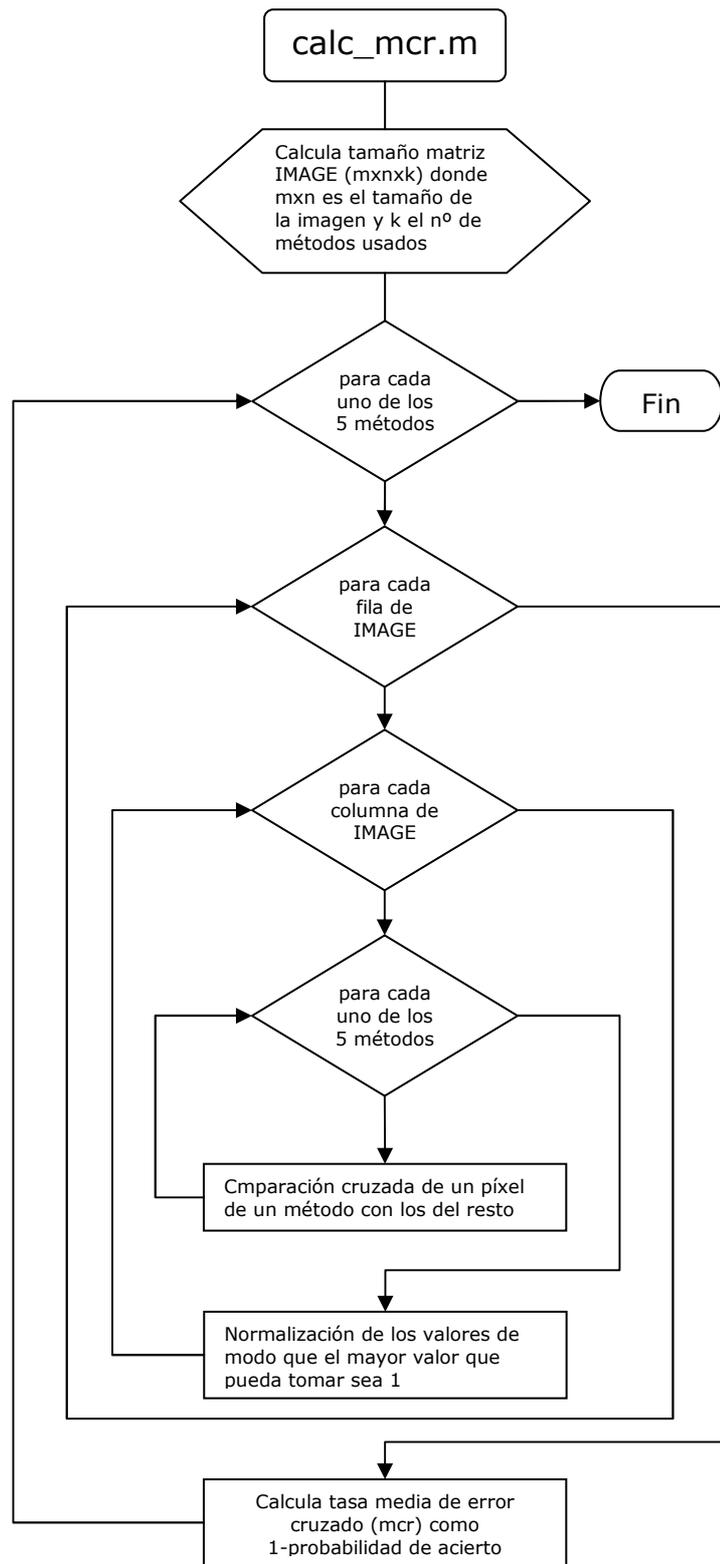


Figura 26. Diagrama de flujo de la función “calc_mcr.m”

Más adelante se explicará más en profundidad en qué consiste la tasa media de error cruzado (MCR) y el algoritmo de clasificación KNN.

3.2. Obtención de la base de datos

El programa que se ha implementado para el desarrollo de este estudio es muy versátil desde el punto de vista que se le puede meter cualquier imagen en cualquiera de los formatos jpg o bmp, y de cualquier tamaño que cargará la base de datos del mismo modo.

En el transcurso del proyecto se han utilizado distintas baterías de muestras de humo para formar distintas base de datos, de donde se han obtenido resultados que posteriormente analizaremos.

Pero tomando una síntesis de lo que ha sido todo el trabajo podemos decir que hemos trabajado con dos bases de datos distintas.

La primera de ellas se ha obtenido tomando muestras de una fotografía de humo de uno de los fuegos controlados de Gestosa.

En nuestro trabajo utilizamos el método KNN donde se necesitan muestras de distintos clases. Nosotros hemos tomado dos clases distintas:

Tipos de clase {

- clase 1 : muestras de humo
- clase 2 : muestras de no - humo (elementos de textura que consideramos como distintos de la textura del humo : cielo, tierra, plantas, árboles...)

La segunda base de datos es una ampliación de la primera, donde se han añadido cuatro muestras de la clase humo, y cuatro muestras de la clase no-humo, tomadas de distintas fotografías también de las quemadas de Gestosa.

Ponemos a continuación las dos bases de datos con la imagen original y las muestras tomadas:

Base de datos A



Figura 27. Muestras obtenidas para la base de datos

Clase 1: humo (db)



Figura 28. Muestras de la clase humo

Clase 2: no-humo (nodb)

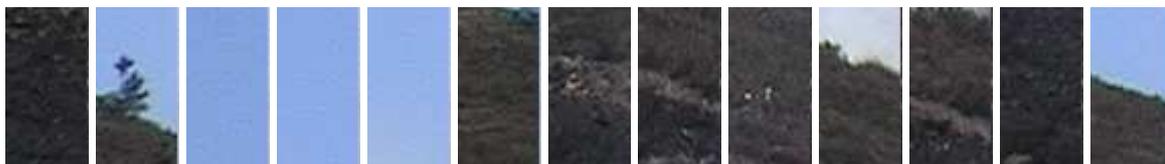


Figura 29. Muestras de la clase no-humo

Base de datos B

Añadimos cuatro muestras a cada una de las clases humo y no-humo anteriores, obtenidas de otras imágenes de humo.





Figura 30. Muestras añadidas a la base de datos para formar la base de datos ampliada

Clase 1: humo (db)



Figura 31. Muestras de clase humo ampliadas con cuatro muestras

Clase 2: no-humo (nodb)



Figura 32. Muestras de clase no-humo ampliadas con cuatro muestras

• Creación de la base de datos para el programa

Para cada muestra de la base de datos, el programa “creaDB.m” saca unos archivos que el programa principal usa para los distintos métodos. Vamos a ver un ejemplo.

Supongamos que tenemos una muestra de la clase humo.

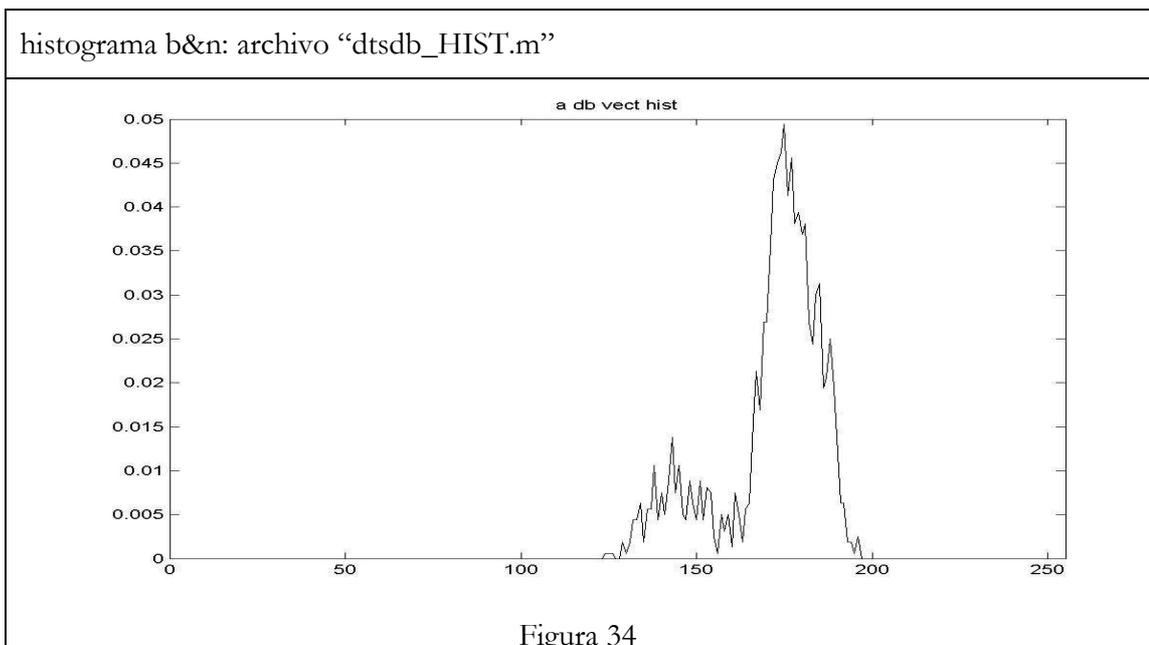


Figura 33. a_db.bmp

Las salidas que da el programa “creaDB.m” son:

Para **histograma b&n**:

archivo: “a_db.doc” y “a_db.m” (almacena vector de descriptores)
Datos de entrada: inname=`DBhist_B&N/a_db.bmp` tamaño imagen=40x40 n_colores=0 Los descriptores del histograma son: Media, Desviacion estandar, Tercer momento y Entropia Media Desv.est. 3er momento Entropia F=[170.521250 14.437609 5323.780269 5.470709];



Para **histograma color**:

archivo: “a_db.doc” y “a_db.m” (almacena vector de descriptores)

Datos de entrada:

```
inname='DBhist_C/a_db.bmp'
tamaño imagen=40x40
n_colores=3
```

Los descriptores del histograma son: Media, Desviacion estandar, Tercer momento y Entropia

```
Media    Desv.est.  3er momento  Entropia
F=[150.132500  11.280733  2666.444591  5.099360
167.703750  14.056439  4986.096614  5.359958
193.765000  18.882062  11439.311891  5.958941];
```

histograma color: archivo “dtsdb_HISTc.m”

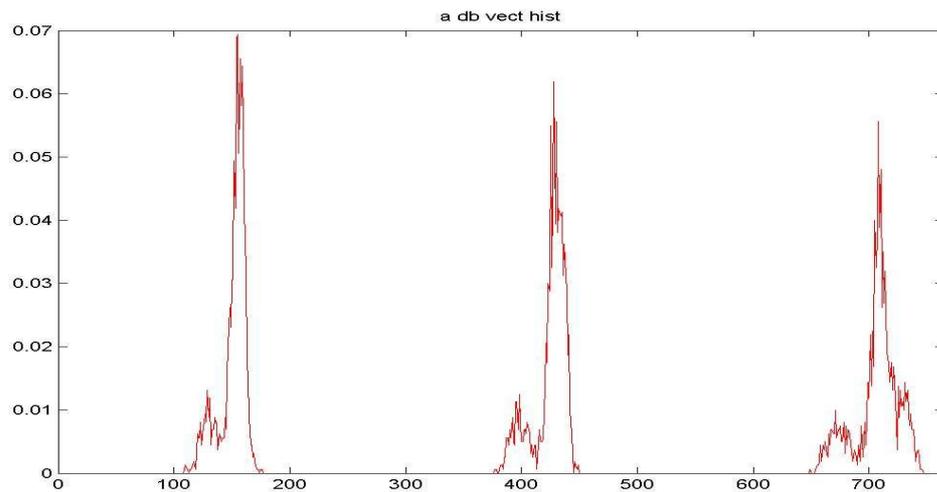


Figura 35

Para **matriz de coocurrencia b&n**:

archivo: “a_db.doc” y “a_db.m” (almacena vector de descriptores)

Datos de entrada:

```
inname='DBcooc_B&N/a_db.bmp'
tamaño imagen=40x40
n_colores=0
dir_busqueda='ru'
tamaño C=16x16
```

Los descriptores de la matriz de coocurrencia son: energia, entropia, contraste, homogeneidad y correlacion
Cada fila de datos corresponde a una direccion de busqueda. Sigue el orden de dir_busqueda.

Para la imagen en escala de grises

Energia	Entropia	Contraste	Homogeneidad	Correlacion
0.206085	2.813515	0.359211	0.844463	0.033999
0.198231	2.933097	0.469079	0.827083	0.031046

Tiempo de ejecucion: 0.2 segundos

histograma b&n: archivo “dtsdb_COOC.m”

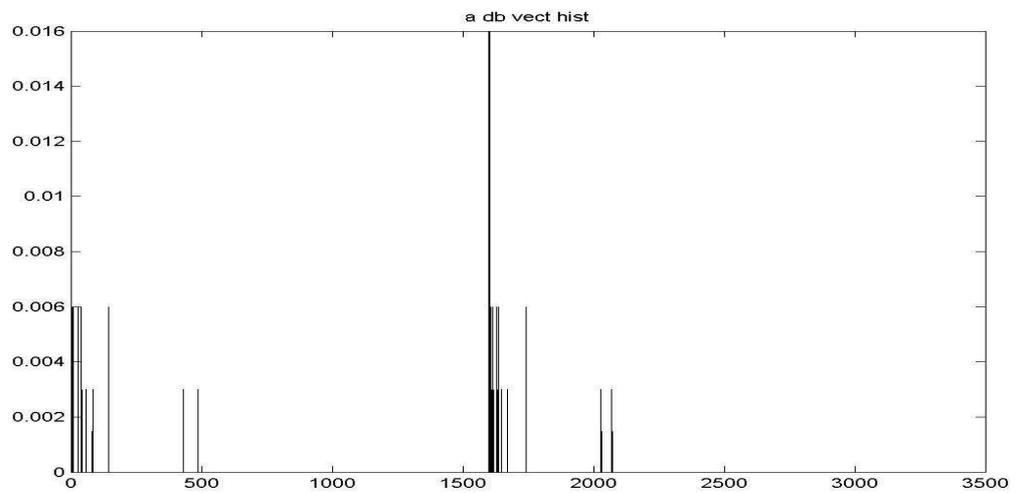


Figura 36

Para **matriz de coocurrencia color:**

archivo: “a_db.doc” y “a_db.m” (almacena vector de descriptores)

Datos de entrada:

```

inname='DBcooc_C/a_db.bmp'
tamaño imagen=40x40
n_colores=3
dir_busqueda='ru'
tamaño C=16x16
    
```

Los descriptores de la matriz de coocurrencia son: energia, entropia, contraste, homogeneidad y correlacion. Cada fila de datos corresponde a una direccion de busqueda. Sigue el orden de dir_busqueda.

Para los tonos azules...

Energia	Entropia	Contraste	Homogeneidad	Correlacion
0.346627	2.389994	0.355263	0.849616	0.017704
0.335669	2.499548	0.453947	0.829934	0.014971

Para los tonos verdes...

Energia	Entropia	Contraste	Homogeneidad	Correlacion
0.221780	2.762625	0.358553	0.853783	0.031826
0.210369	2.911095	0.501974	0.825603	0.028185

Para los tonos rojos...

Energia	Entropia	Contraste	Homogeneidad	Correlacion
0.190231	3.254256	0.365132	0.845724	0.079182
0.171253	3.446710	0.531579	0.816447	0.073650

Tiempo de ejecucion: 0.5 segundos

histograma b&n: archivo "dtsdb_COOCc.m"

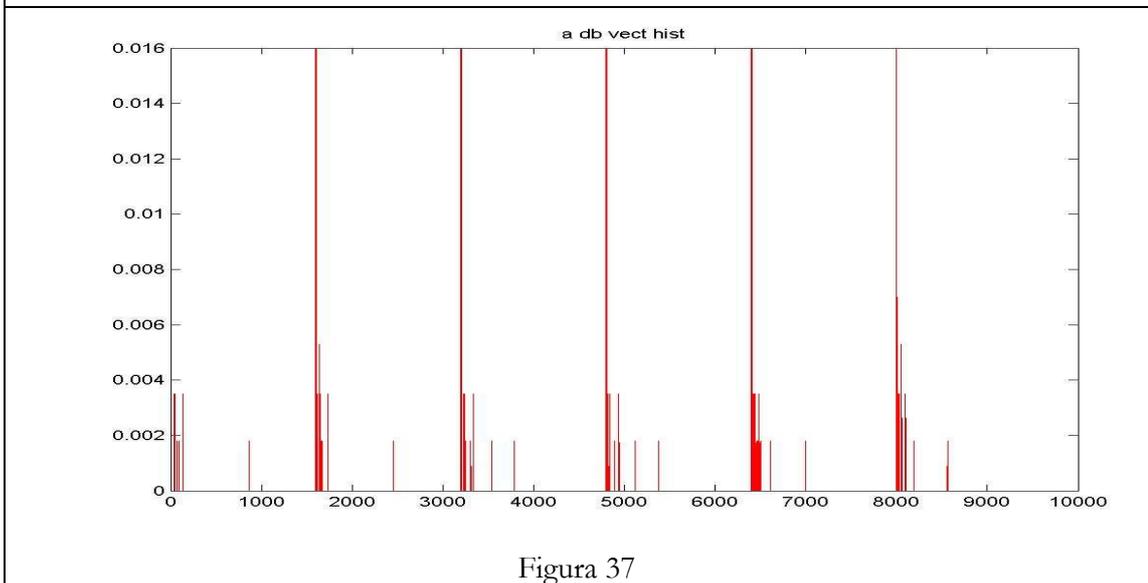


Figura 37

Para **Simplified Texture Unit (STU)**:

archivo: "a_db_stu1_0.m"

Almacena la matriz de los números N_{STU1} :

El nombre del archivo se compone de:

- "a_": nombre de la muestra de textura
- "db_": la muestra pertenece a la clase humo
- "stu1": se usa el descriptor STU_1 . También puede ser "stu2"
- Hay una versión del programa que puede ser "stuC" en vez de "stu". Esta versión incluye información del color.
- "0": Valor del parámetro de tolerancia "delta".

histograma de N_{STU1} : archivo "dtsdb_STU.m"

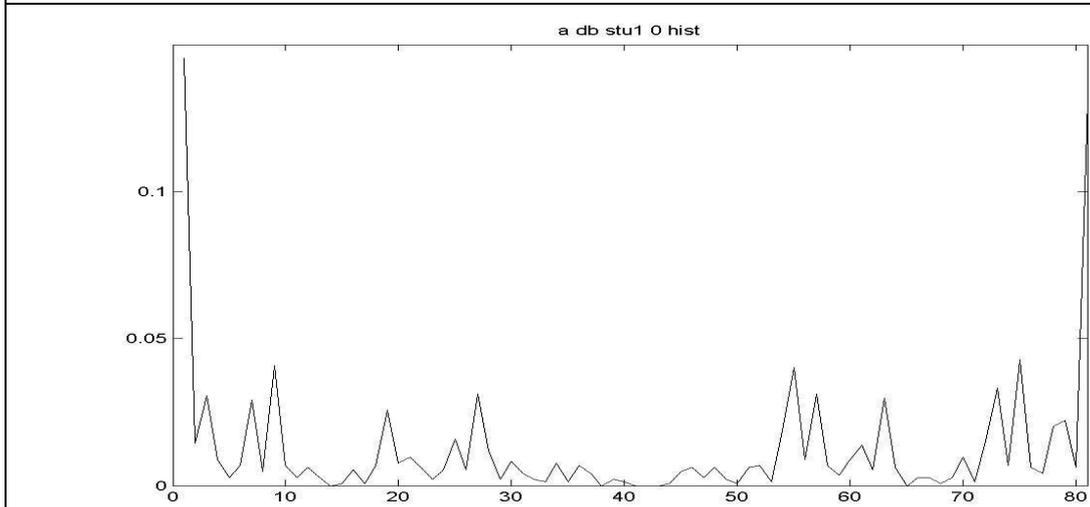


Figura 38

Estas salidas se obtienen para cada muestra de la base de datos. Los histogramas que hemos representado arriba se usan con valores numéricos, pero lo hemos puesto así para que se observe mejor cada histograma.

El programa "creaDB.m", para el método de Histograma saca además la representación gráfica de todos los histogramas de las muestras.

Para la **Base de datos 1**, se han obtenido los siguientes histogramas para todas las muestras.

- **Histograma blanco y negro:**

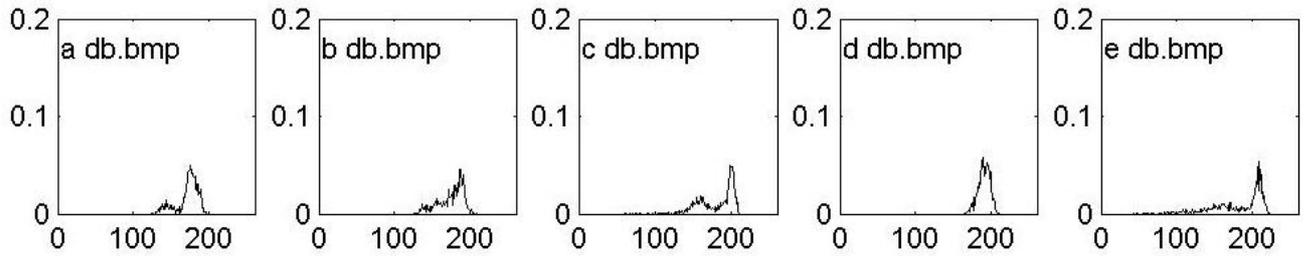


Figura 39. Muestras de clase humo de imágenes en escala de grises

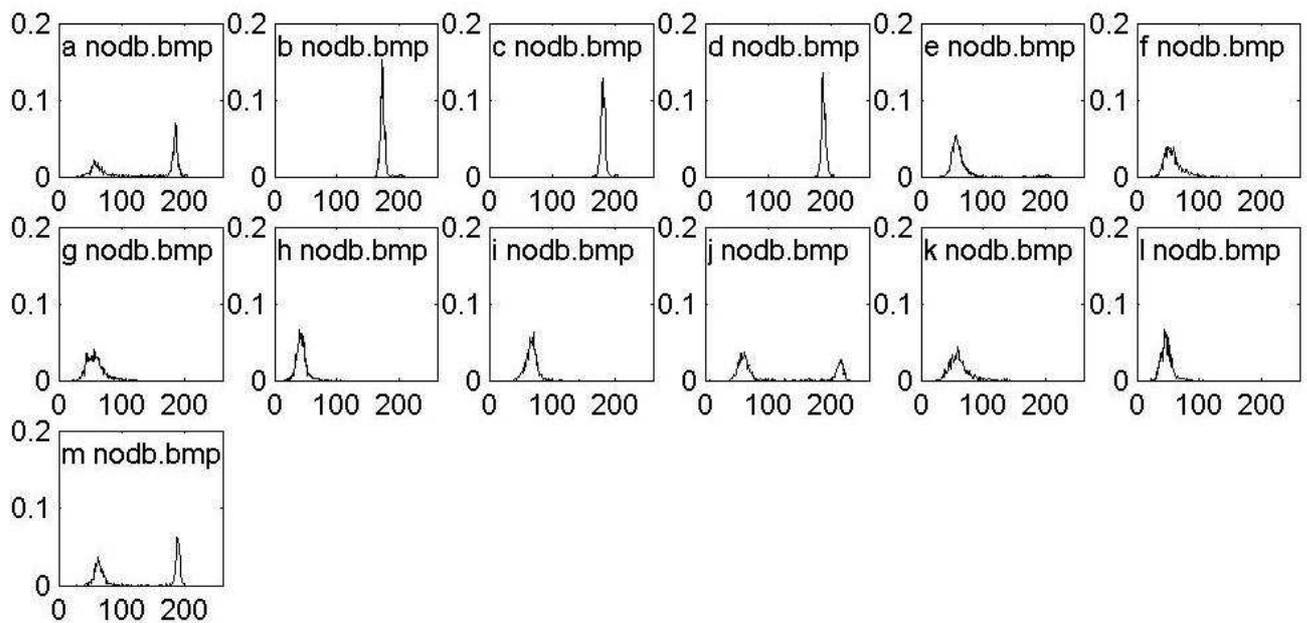


Figura 40. Muestras de clase no- humo de imágenes en escala de grises

- **Histograma color:**

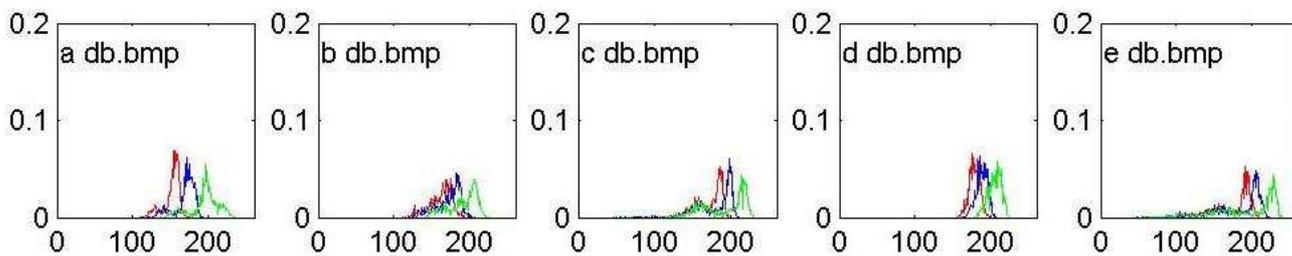


Figura 41. Muestras de clase humo con superposición de histogramas de las capas RGB

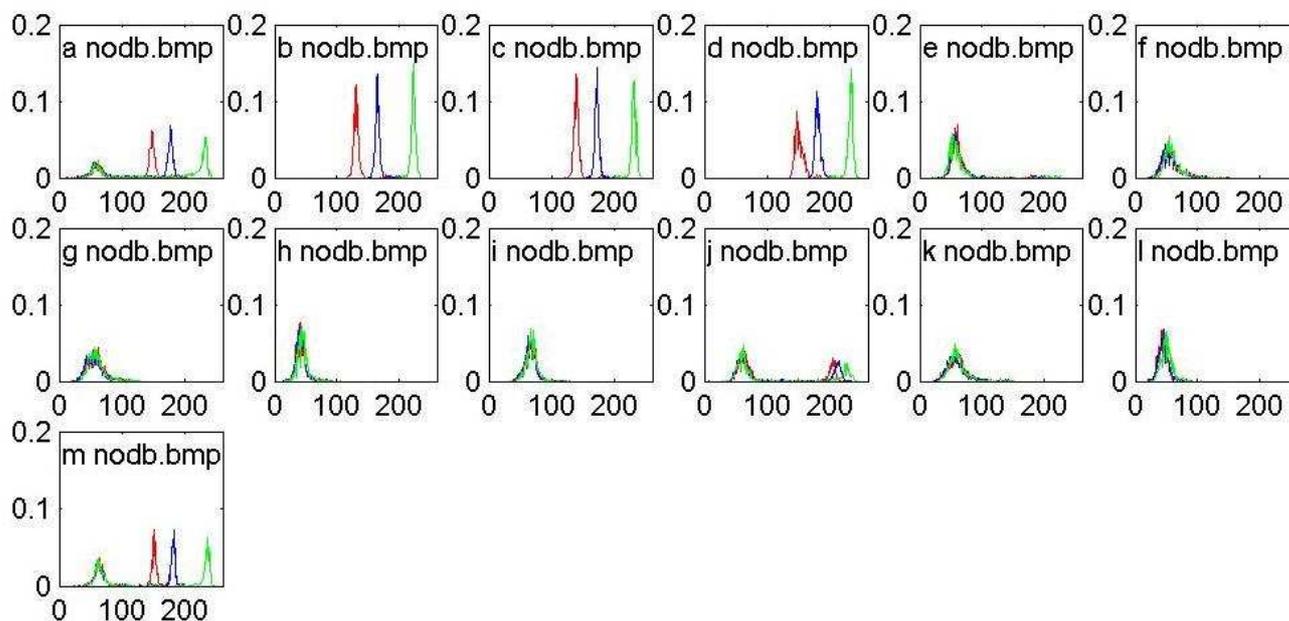


Figura 42. Muestras de clase no-humo con superposición de histogramas de las capas RGB

Para la **Base de datos 2**, se han obtenido los siguientes histogramas.

- **Histograma blanco y negro:**

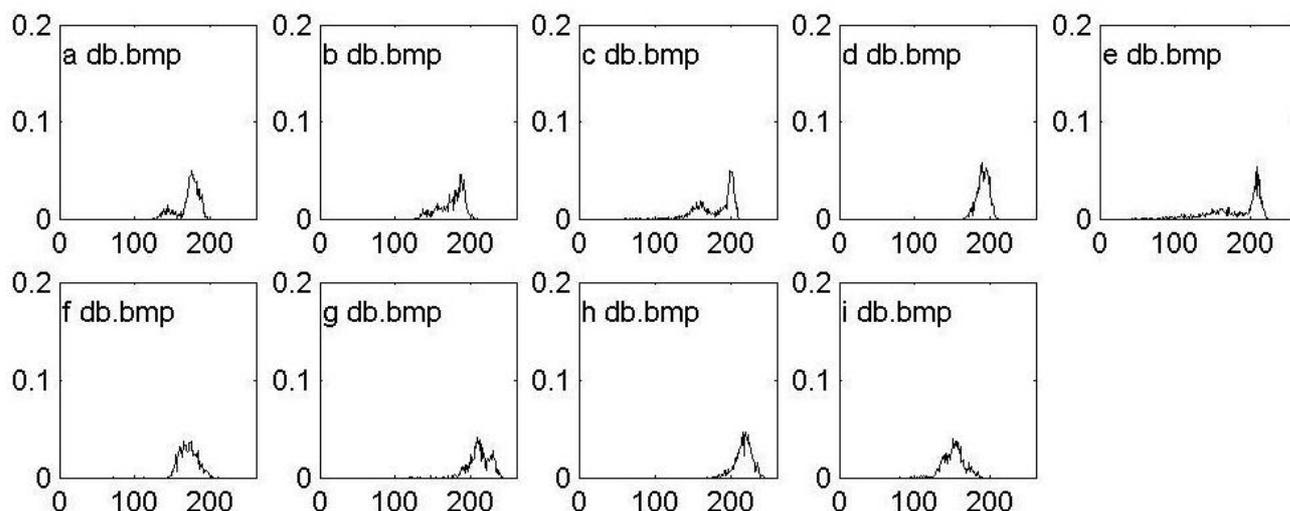


Figura 43. Muestras de clase humo de imágenes en escala de grises

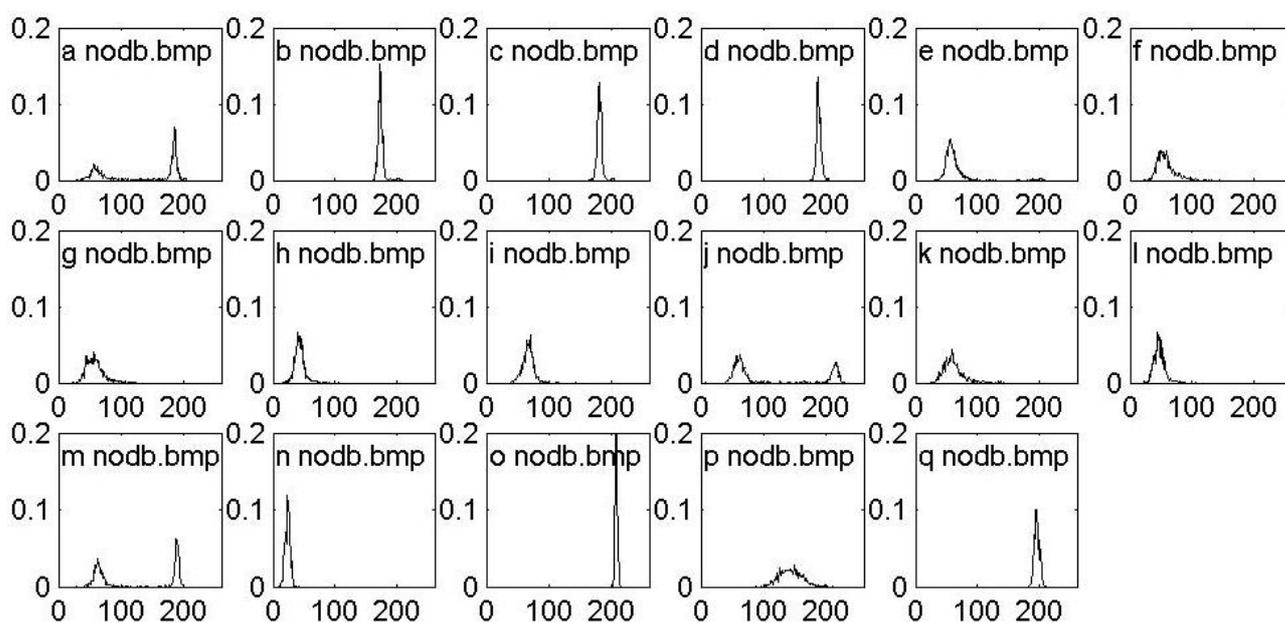


Figura 44. Muestras de clase no- humo de imágenes en escala de grises

- **Histograma color:**

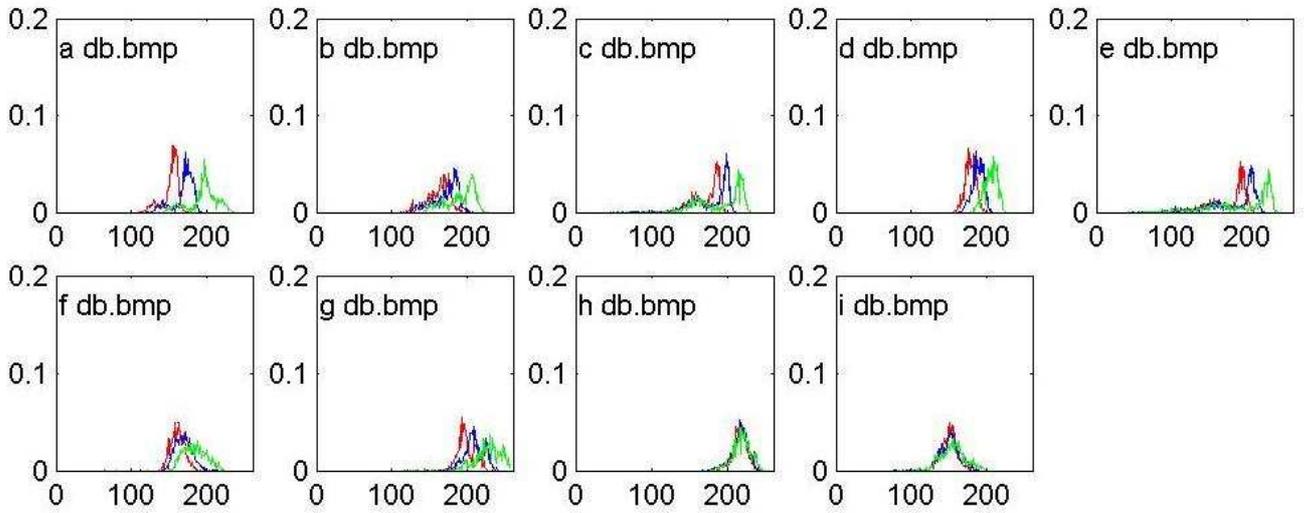


Figura 45. Muestras de clase humo con superposición de histogramas de las capas RGB

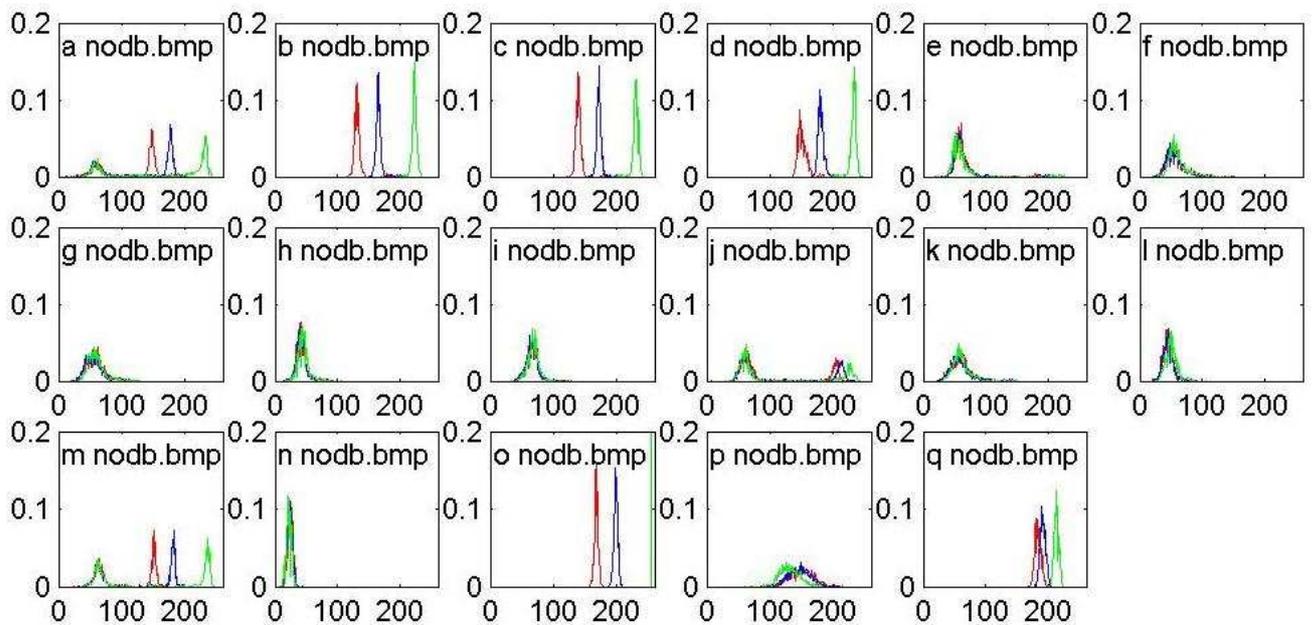


Figura 46. Muestras de clase no-humo con superposición de histogramas de las capas RGB

4. Estudio Comparativo

4.1. Obtención de las imágenes de humo

En estos últimos años se ha estado llevando a cabo un proyecto llamado Proyecto Inflamm, dedicado a la investigación en incendios forestales incluyendo métodos de adquisición de información, modelado, y soporte a la extinción. En este proyecto, entre otros participa AICIA de la Universidad de Sevilla, que se encarga de desarrollar sistemas de percepción para la monitorización de fuegos forestales. En este proyecto se han desarrollado nuevas técnicas de medida empleando cámaras visuales, cámaras de infrarrojos y GPS, investigando en procesamiento de secuencias de imágenes para la segmentación y el seguimiento visual del fuego. Se han empleado técnicas específicas de filtrado. Se han obtenido modelos en tres dimensiones del incendio que se representan de forma apropiada para su visualización. Se han desarrollado también funciones de estimación de la evolución del incendio de interés para la validación de los modelos de comportamiento. En el segundo año del proyecto se ha desarrollado e integrado una herramienta informática que permite aplicar en tiempo real las técnicas mencionadas.

Lo que en nuestro proyecto más interesa es que, el proyecto Inflamm, entre otros experimentos, participó de las quemas controladas realizadas en Mayo de 2001 en Gestosa, cerca de Coimbra (Portugal), utilizando simultáneamente diversas cámaras, visuales y en el infrarrojo, situadas en tierra y en helicópteros dotados de GPS. Se obtuvieron medidas de la altura de las llamas, avance del frente, anchura del frente y velocidad de propagación, en tiempo real, aplicando técnicas de visión por computador, georreferenciación y fusión sensorial (figura 11).

La batería de fotografías que se obtuvo en la quema de Gestosa es de la que hemos dispuesto para el estudio de los distintos métodos que se realizan en este proyecto. De todas las imágenes que ocupan más de 4Gb de memoria se han seleccionado un conjunto de ellas de las que se han sacado muestras para su tratamiento y estudio aplicado a los distintos métodos.

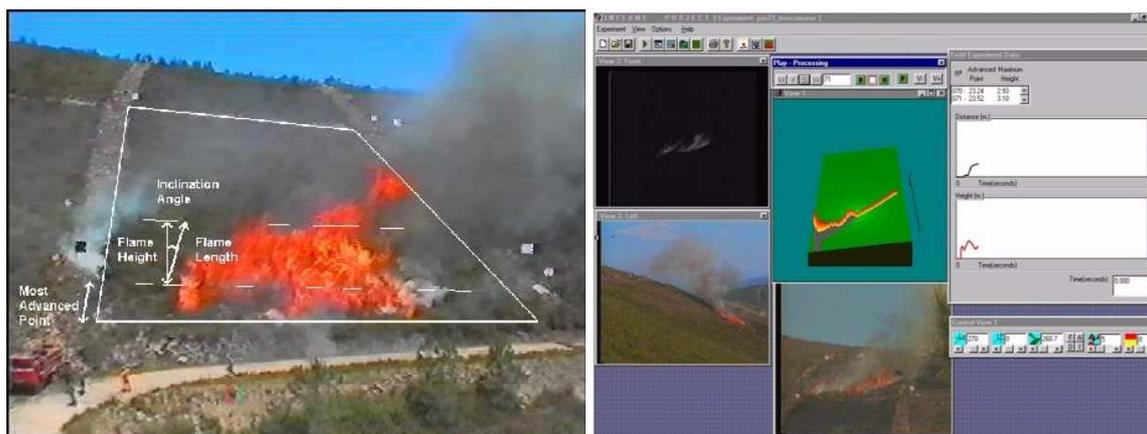


Figura 47. Entornos de aplicación utilizados en el proyecto INFLAME

Es importante decir que las imágenes que se han utilizado en el proyecto son imágenes entrelazadas con líneas verticales, debido al funcionamiento de las imágenes utilizadas. Esto quiere decir que una fotografía se compone realmente de dos imágenes superpuestas, donde si analizásemos fila a fila la imagen, las filas impares pertenecerían a una de las imágenes superpuestas y las filas pares a la otra imagen superpuesta. Es por esto que en nuestro programa sólo nos quedamos con una de las dos imágenes superpuestas.

4.2. Estudio comparativo de los distintos métodos según sus características

Para cada uno de los métodos que se han implementado, existen una serie de características que se deben especificar y de las que dependerá en cierto modo su comportamiento.

Son una serie de parámetros que se deben ajustar para obtener un buen funcionamiento a la hora de realizar el estudio comparativo entre los distintos métodos. La elección de los parámetros de cada método se debe realizar atendiendo a la naturaleza del objetivo que se esté buscando.

A la hora de hacer las pruebas, observando la eficacia de cada método, y obteniendo la tasa de error de cada método, se han propuesto unos parámetros que traten de optimizar la tasa de error. Aun así, un estudio más detenido de estos parámetros podrían mejorar los resultados obtenidos.

En este apartado se va a realizar un estudio de los distintos métodos atendiendo a la dinámica interna de cada uno. Es decir, se van a realizar pruebas cambiando sus parámetros internos y se va a tratar de deducir el valor óptimo de los mismos.

A continuación vamos a presentar cuáles son los parámetros que se pueden modificar para cada método.

En la columna “Parámetro” se han puesto en negrita los parámetros que se van a estudiar mediante gráficas para ver cuáles son los valores óptimos. El resto de parámetros que no están en negrita, aunque se podrían modificar, no son tales que los resultados del método puedan variar con las imágenes de humo que estamos tratando. Sólo se han estudiado los parámetros que se han considerado más relevantes.

Parámetros de **Histograma Blanco y Negro**

Parámetro	Descripción	Valores posibles	Valor elegido
‘colores’	modo de transformar la imagen con color a escala de grises	media de capas capas sueltas	media aritmética: (R+G+B)/3
‘ventana’	tamaño de ventana de desplazamiento que se desliza por la imagen	$n \times n, n \in \mathbb{N}$	30x30 píxeles
‘tipoclasif’	método de clasificación: usar los descriptores del histograma o el mismo histograma	‘descr’ ‘hist’	‘hist’
medida de distancia	modos de medir distancias de un vector a otro	‘descr’ \rightarrow L2 ‘hist’ \rightarrow L1, Chi ² , Intersecc. de Hist.	hist \rightarrow Chi ²
k	parámetro KNN	$k \in \mathbb{N}$	k=2

Tabla 9. Parámetros del método del Histograma en blanco y negro

Parámetros de **Histograma Color**

Parámetro	Descripción	Valores posibles	Valor elegido
'colores'	modo de usar la imagen con colores	1 color: R 2 colores: R+G 3 colores: R+G+B	R+G+B
'ventana'	tamaño de ventana de desplazamiento que se desliza por la imagen	$n \times n$, $n \in \mathbb{N}$	30x30 píxeles
'tipoclasif'	método de clasificación: usar los descriptores del histograma o el mismo histograma	'descr' 'hist'	'hist'
medida de distancia	modos de medir distancias de un vector a otro	'descr' \rightarrow L2 'hist' \rightarrow L1, Chi ² , Intersecc. de Hist.	hist \rightarrow L1
k	parámetro KNN	$k \in \mathbb{N}$	k=2

Tabla 10. Parámetros del método del histograma en color

 Parámetros de **Coocurrencia Blanco y Negro**

Parámetro	Descripción	Valores posibles	Valor elegido
'colores'	modo de transformar la imagen con color a escala de grises	media de capas capas sueltas	media aritmética: $(R+G+B)/3$
'dir_búsqueda'	dirección(es) de búsqueda para calcular la matriz de coocurrencia	'r' – dcha (+ izda) 'u' – arriba (+ abajo) 'e' – diagonal dcha 'w' – diagonal izda o combinaciones	'ru'

'q'	exponente de reducción de la dimensión de la matriz de coocurrencia	$q \in [0,6]$ si $q=0 \rightarrow 256 \times 256$ si $q=1 \rightarrow 128 \times 128$ si $q=2 \rightarrow 64 \times 64$ si $q=3 \rightarrow 32 \times 32$ si $q=4 \rightarrow 16 \times 16$ si $q=5 \rightarrow 8 \times 8$ si $q=6 \rightarrow 4 \times 4$	$q = 4$
'd'	vector de distancia	$d > 0$	$d = 1$
'ventana'	tamaño de ventana de desplazamiento que se desliza por la imagen	$n \times n, n \in \mathbb{N}$	40x40 píxeles
'tipoclasif'	método de clasificación: usar los descriptores del histograma o el mismo histograma	'descr' 'hist'	'descr'
medida de distancia	modos de medir distancias de un vector a otro	'descr' \rightarrow L2 'hist' \rightarrow L1, Chi ² , Intersecc. de Hist.	descr \rightarrow L2
k	parámetro KNN	$k \in \mathbb{N}$	$k=2$

Tabla 11. Parámetros del método de la matriz de co-ocurrencia en blanco y negro

 - Parámetros de **Coocurrencia Color**

Parámetro	Descripción	Valores posibles	Valor elegido
'colores'	modo de usar la imagen con colores	1 color: R 2 colores: R+G 3 colores: R+G+B	R+G+B
'dir_búsqueda'	dirección(es) de búsqueda para calcular la matriz de coocurrencia	'r' – dcha (+ izda) 'u' – arriba (+ abajo) 'e' – diagonal dcha 'w' – diagonal izda o combinaciones	'ru'

'q'	exponente de reducción de la dimensión de la matriz de coocurrencia	$q \in [0,6]$ si $q=0 \rightarrow 256 \times 256$ si $q=1 \rightarrow 128 \times 128$ si $q=2 \rightarrow 64 \times 64$ si $q=3 \rightarrow 32 \times 32$ si $q=4 \rightarrow 16 \times 16$ si $q=5 \rightarrow 8 \times 8$ si $q=6 \rightarrow 4 \times 4$	$q = 4$
'd'	vector de distancia	$d > 0$	$d = 1$
'ventana'	tamaño de ventana de desplazamiento que se desliza por la imagen	$n \times n, n \in \mathbb{N}$	40x40 píxeles
'tipoclasif'	método de clasificación: usar los descriptores del histograma o el mismo histograma	'descr' 'hist'	'descr'
medida de distancia	modos de medir distancias de un vector a otro	'descr' $\rightarrow L2$ 'hist' $\rightarrow L1, Chi^2,$ Intersecc. de Hist.	descr $\rightarrow L2$
k	parámetro KNN	$k \in \mathbb{N}$	$k=2$

Tabla 12. Parámetros del método de la matriz de co-ocurrencia en color

- Parámetros de la **Simplified Texture Unit (STU)**

Parámetro	Descripción	Valores posibles	Valor elegido
'tipo'	tipo de stu que se va a calcular, se-gún se tomen los píxeles en cruz (stu1) o en diagonal (stu2)	stu '1' stu '2'	tipo = '1'
'delta'	tolerancia a la hora de renombrar los píxeles vecinos al píxel central	$\delta \in \mathbb{N}$	$\delta = 0$

'ventana'	tamaño de ventana de desplazamiento que se desliza por la imagen	$n \times n, n \in \mathbb{N}$	40x40 píxeles
'stu_weights'	pesos que se les dan a cada uno de los píxeles vecinos transformados	[a b c d], pueden tomar cualquier valor	[1 3 9 27]
medida de distancia	modos de medir distancias de un vector a otro	L1, Chi ² , Intersecc. de Hist.	Intersecc. de histogramas
k	parámetro KNN	$k \in \mathbb{N}$	k=2

Tabla 13. Parámetros del método STU

En este proyecto se han utilizado los parámetros señalados en la columna “valores usados”, que han dado muy buen resultado. Ahora, para observar qué ocurriría cambiando algunos parámetros vamos a estudiar cada método, dejando todos los parámetros constantes y variando uno solo. Así, observando la variación de la tasa de error MCR se verá la evolución de cada método según cada parámetro. Hay que tener en cuenta que al hacer cambios en el método, hay que cambiar también la base de datos. Es decir, hay ciertos parámetros que para que los resultados sean veraces, se debe recrear la base de datos teniendo en cuenta estos nuevos valores de los parámetros.

Para ello, cuando sólo se necesite una imagen para estudiar el parámetro se va a utilizar una de las imágenes de humo de Gestosa con la base de datos ampliada. Cuando se necesiten más imágenes se utilizarán una batería de fotografías también tomadas de Gestosa.

La imagen de humo que vamos a utilizar es “w.bmp”.



Figura 48. Imagen usada para estudio de parámetros.

- **Estudio de los parámetros de Histograma en blanco y negro**

Parámetro: 'ventana'

Hay que tener en cuenta que la base de datos está formada con muestras de tamaño 40x40 píxeles, que se a elegido así por la naturaleza de la textura del humo. Se va a modificar el tamaño de 'ventana' alrededor del tamaño de las muestras de la base de datos.

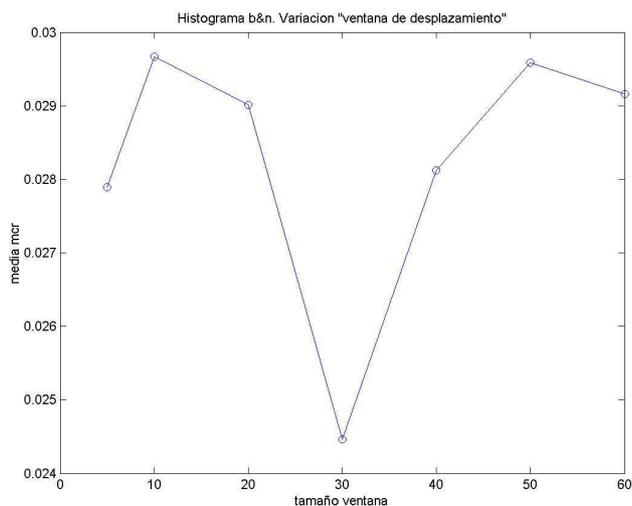
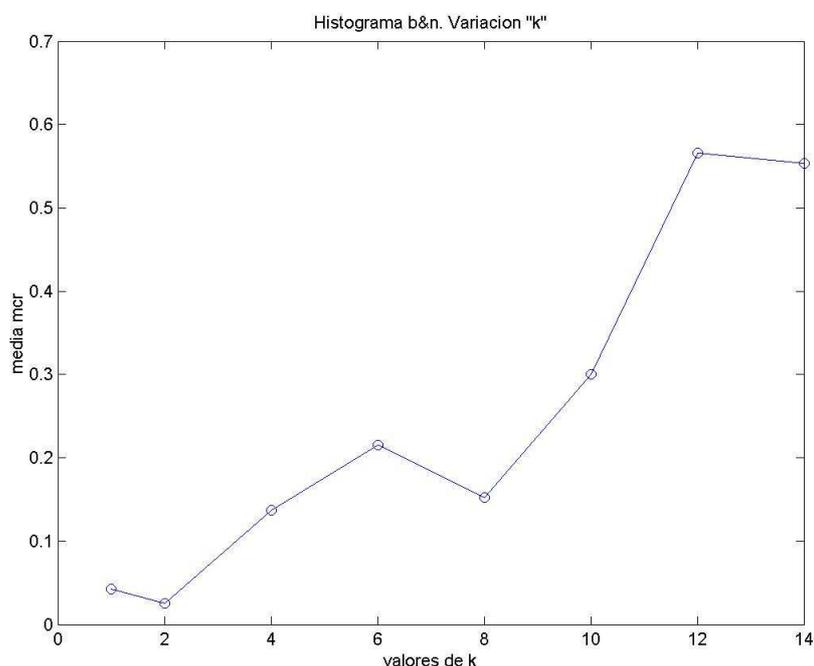


Figura 49. Histograma b&n. Variación "Ventana de desplazamiento"

Para esta gráfica no se ha modificado el tamaño de las muestras de la base de datos. Aun así se observa que la menor tasa de error se encuentra no en 40, que es el tamaño de las muestras de la base de datos sino en 30. Pero se puede observar que el mínimo de la media mcr se encuentra en los alrededores del tamaño de las muestras de la base de datos, aumentando el error conforme nos separamos de este tamaño.

Parámetro: k (k-nearest neighbors)*Figura 50. Histograma b&n. Variación "k"*

En el caso del método del histograma, tanto en color como en blanco y negro, cuanto menor es el parámetro k menor es el error. Que el mínimo esté en $k = 2$ significa a la hora de coger los dos elementos de la base de datos más cercanos a la muestra en cuestión, estos dos elementos pertenecían a la clase humo.

Por otro lado, que el mínimo esté en este valor de k quiere decir que es el valor que más se adecua a la clasificación de humo dada la base de datos con el número de muestras tomadas para cada clase, y contando con los resultados de los demás métodos. En los resultados finales se ha tomado $k = 2$ como parámetro de clasificación de knn (k-nearest neighbours).

Parámetro: 'tipoclasif'

Como se ha explicado anteriormente, para clasificar las texturas se pueden usar dos métodos dentro del método del histograma en blanco y negro. Para compararlos vamos a realizar pruebas con varias imágenes de humo utilizando la base de datos ampliada. Se va a

representar en una gráfica, para cada imagen el valor de la tasa de error cruzado (MCR) correspondiente a usar la clasificación por descriptores y la correspondiente a usar la clasificación por histogramas.

Para estas medidas se van a utilizar las medidas de distancia L2 para la clasificación por descriptores y la medida de distancia Chi2 para la clasificación por histogramas.

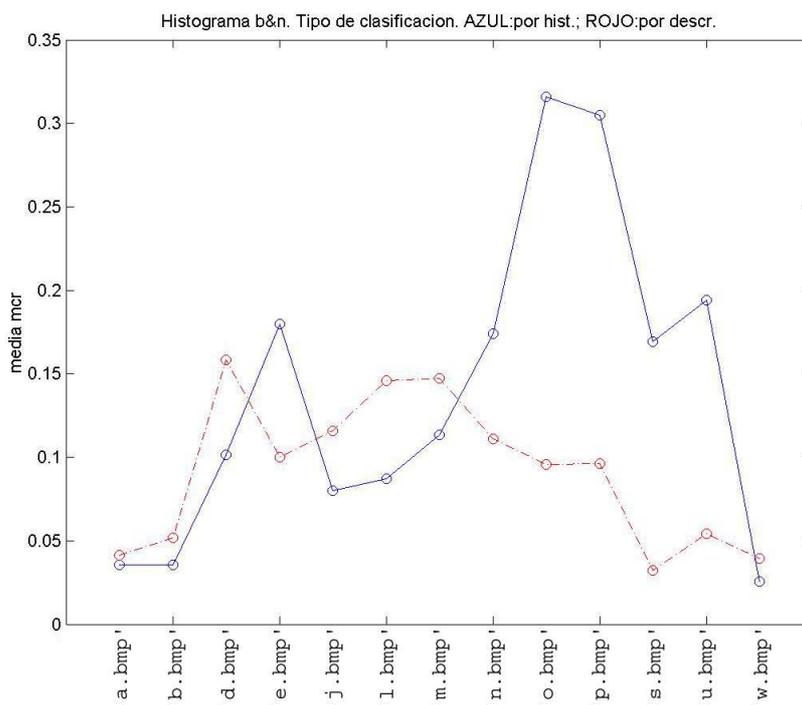


Figura 51. Histograma b&n. Tipo de clasificación.

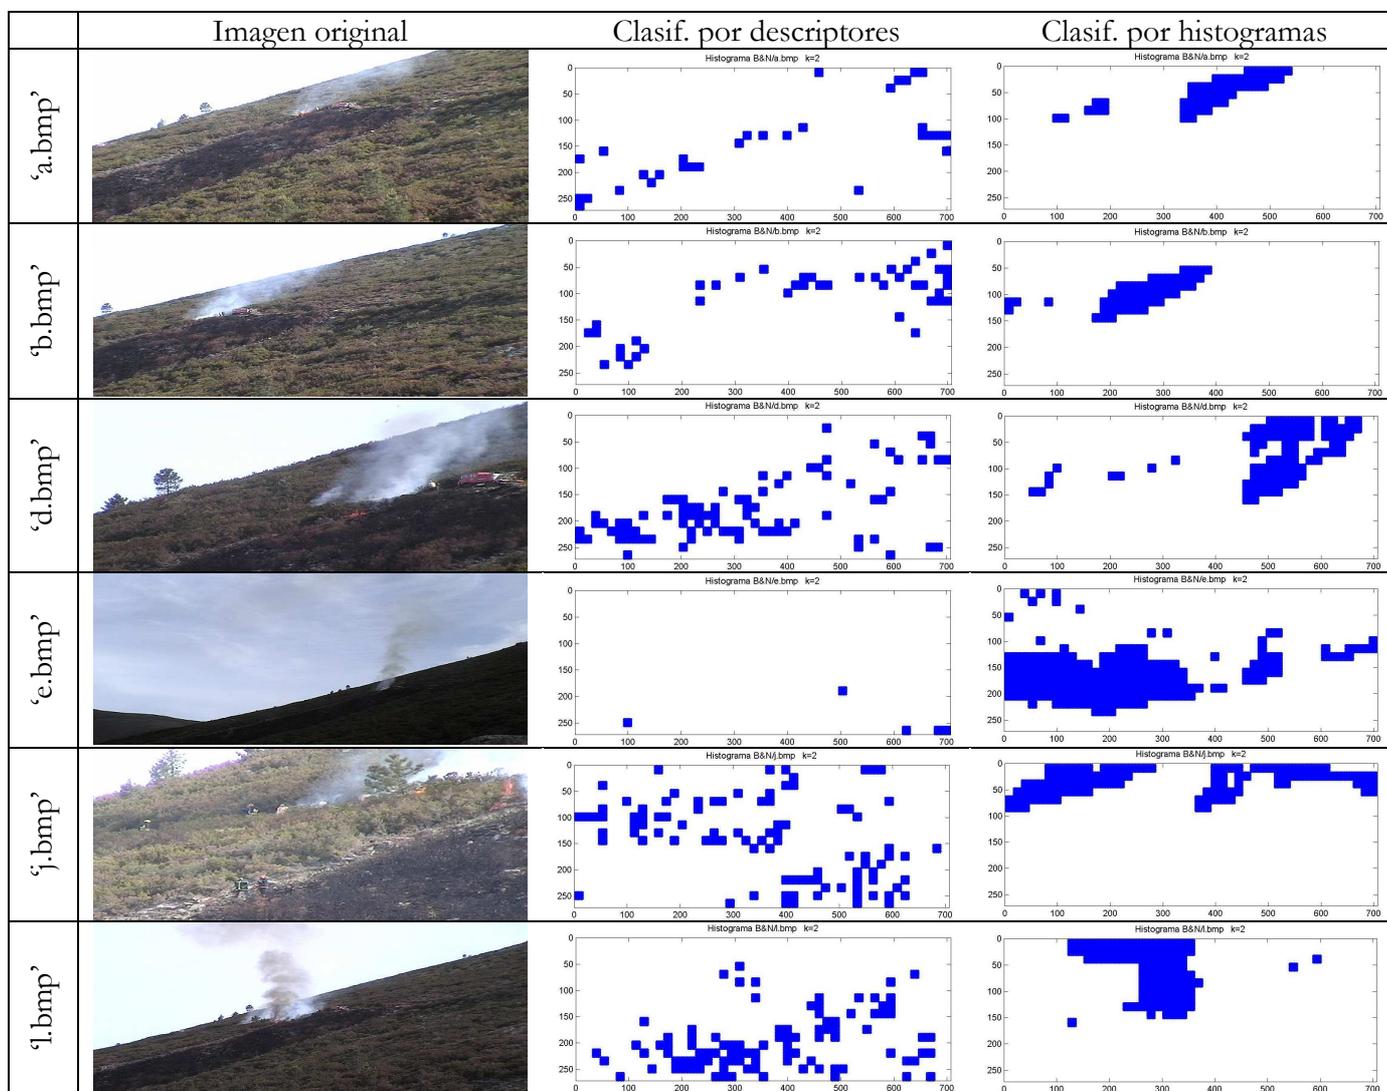
AZUL (—): clasificación por histogramas;

ROJO (- - -): clasificación por descriptores

Se observa que la utilización de clasificación por descriptores tiene una tasa de error mucho más constante, independientemente de que la imagen de humo tenga “falsos amigos” como las nubes, cielo gris, etc. También se puede observar cómo la presencia de nubes en las imágenes provoca una subida grande del error debido a que detecta las nubes como clase humo.

En resumen, aunque observando la gráfica se puede deducir que la clasificación por descriptores es mejor que la clasificación por histogramas, debido que este último se equivoca ante la presencia de nubes grises, esto no es así pues con los histogramas, el humo se sigue detectando igualmente, resultado que interesa a este estudio, mientras que la clasificación por descriptores no es capaz de segmentar la imagen detectando el humo con la exactitud con la que lo hace la clasificación por histogramas.

Esto se puede observar en la segmentación de imágenes a partir de la cual (junto con otras imágenes que no presentamos) se han obtenido las tasas de error mostradas en la gráfica anterior.



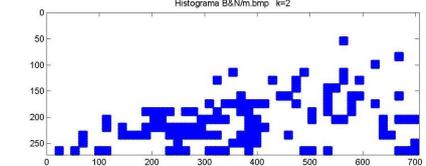
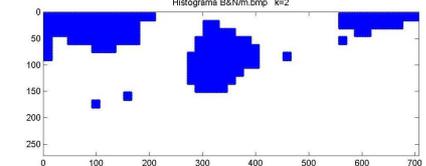
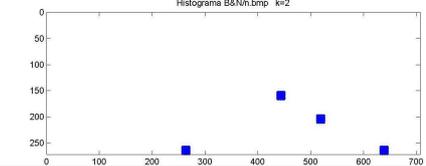
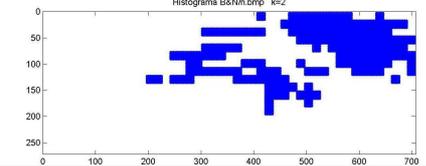
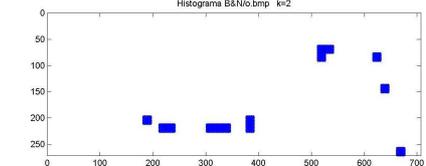
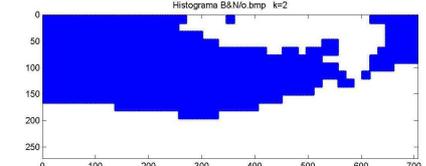
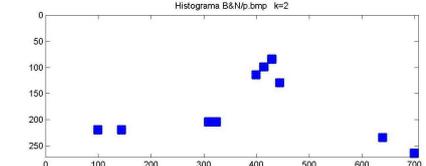
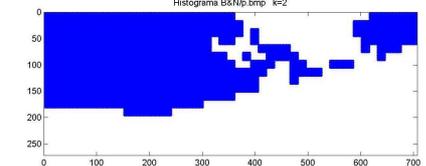
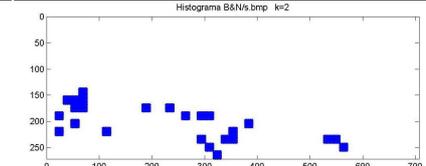
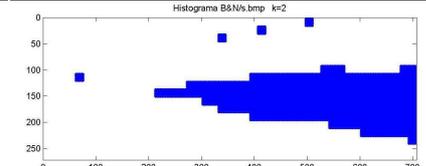
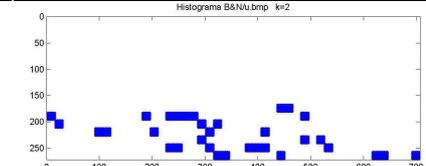
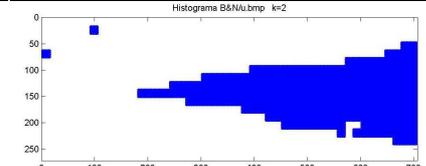
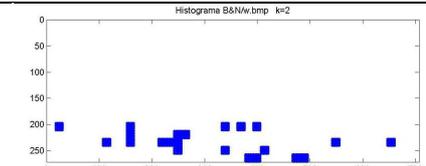
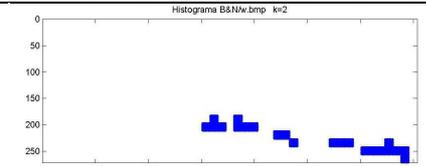
'm.bmp'			
'n.bmp'			
'o.bmp'			
'p.bmp'			
's.bmp'			
'u.bmp'			
'w.bmp'			

Tabla 14. Tabla que compara los resultados obtenidos mediante el método del histograma en blanco y negro utilizando los tipos de clasificación por descriptores y por histograma.

Estudio de los parámetros de Histograma en color

Parámetro: 'ventana'

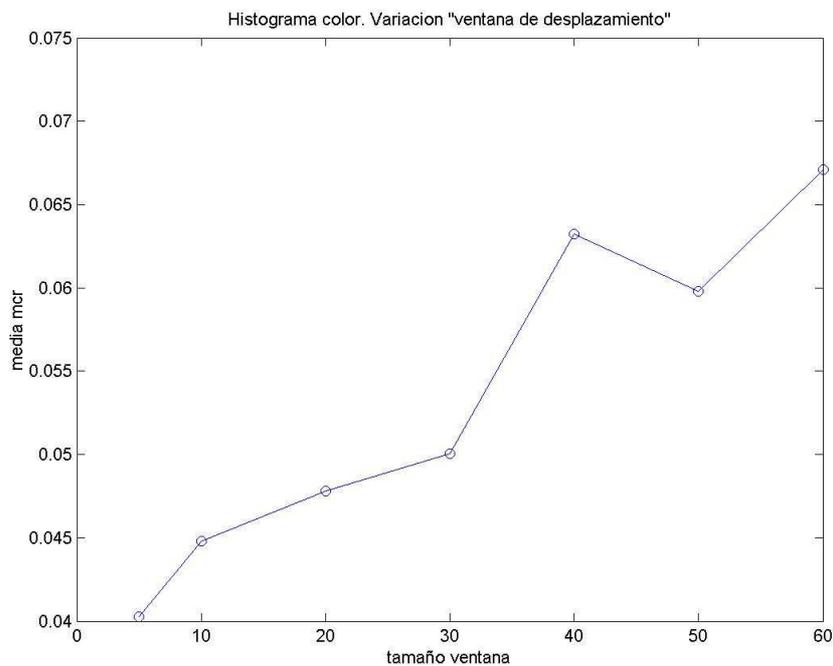


Figura 52. Histograma color. Variación "Ventana de desplazamiento"

Al igual que ocurría con el método en blanco y negro, al disminuir el tamaño de la ventana disminuye la tasa de error cruzado. En cambio, al observar la imágenes segmentadas mostradas a continuación observamos que todas ellas están igualmente segmentadas salvo por la precisión de los puntos donde detecta humo. Este cambio de precisión es el que hace que aumente la tasa de error. Hay que tener en cuenta que la tasa de error se calcula teniendo en cuenta los resultados de los otros métodos.



w.bmp comprimida verticalmente

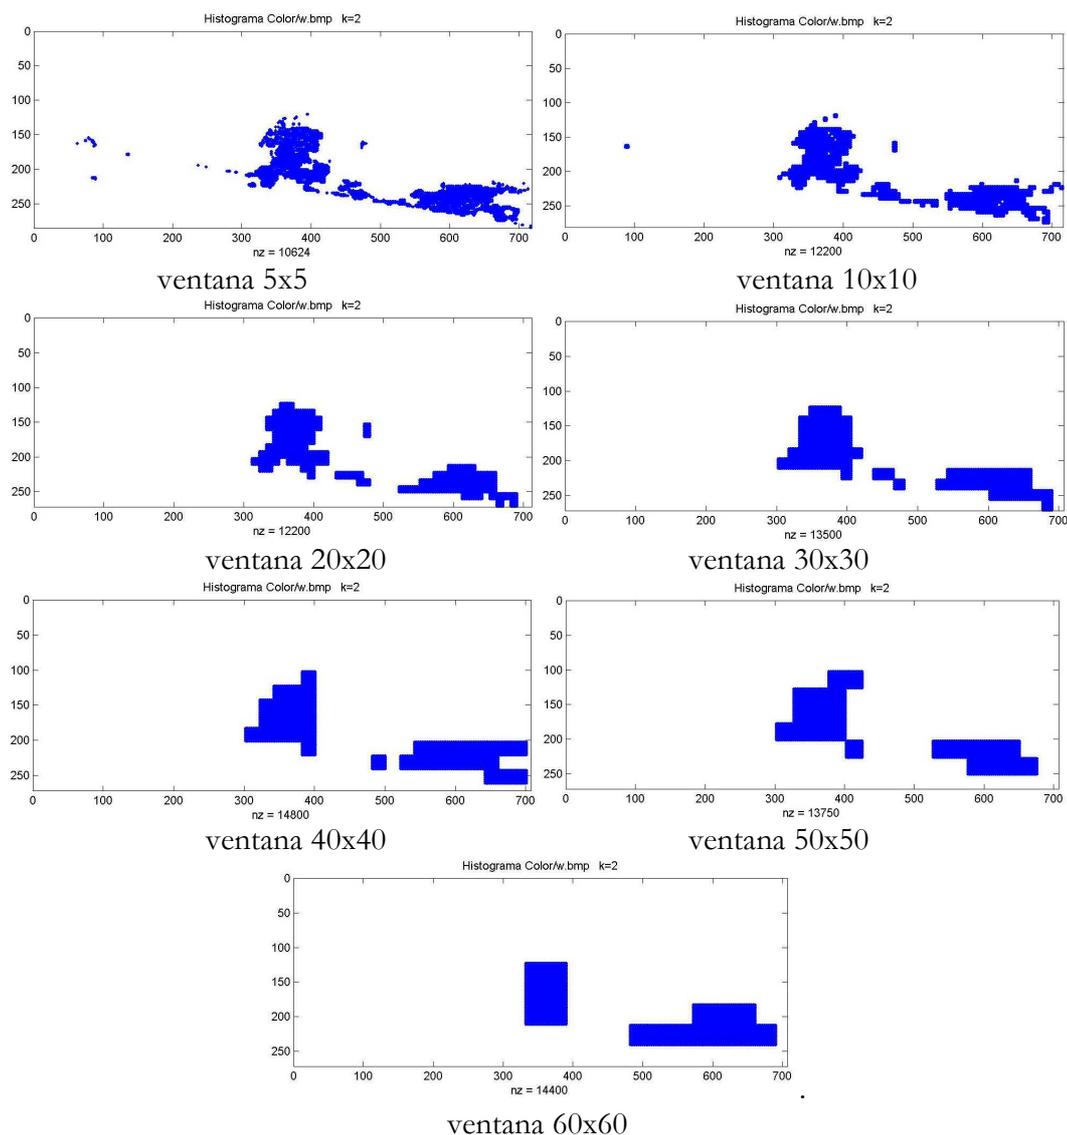


Figura 53. Evolución de los resultados del método de Histograma en color dependiendo del tamaño de la ventana de desplazamiento

En estas imágenes se observa que la detección de humo y la segmentación es la misma en todas las imágenes, es decir, que el tamaño de la ventana no altera la verosimilitud en la segmentación. La diferencia que se observa es la precisión en la localización de los puntos de la clase humo. Se podría decir que a un tamaño de ventana más pequeña el grano de la

segmentación será más fino y viceversa, para un tamaño de ventana grande el grano de la imagen será gordo.

Parámetro: k (k-nearest neighbors)

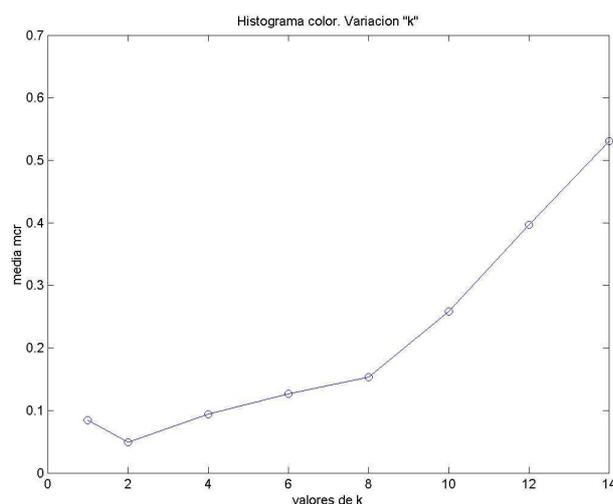


Figura 54. Histograma color. Variación "k"

Esta gráfica es muy parecida a la del histograma en blanco y negro, el mínimo se encuentra en $k = 2$, y va creciendo conforme aumenta el valor de k .

Para el histograma en color mostramos también las imágenes segmentadas que se obtienen del mismo programa que ha obtenido la gráfica anterior. Observamos cómo cambia la segmentación conforme aumentamos la k . Se puede ver que conforme aumenta, aumenta la tolerancia a la hora de decidir qué es y qué no es de la clase humo. Para valores de k muy altos no distingue el humo del cielo. Esto es así pues muchas de las muestras que se han sacado de las imágenes para la clase no-humo pertenecen a la zona de tierra de la imagen, y pocas al cielo, por tanto cuando tenemos que escoger las k muestras de la base de datos más cercanas a la muestra que estamos clasificando (que pertenece al cielo) habrá mucha menos distancia de la muestra del humo a la muestra del cielo, que de la muestra del cielo a la tierra. Por tanto, en las k muestras más cercanas, más de la mitad serán de clase humo, condición que se necesita para que detecte una muestra como clase humo o no.



w.bmp comprimida verticalmente

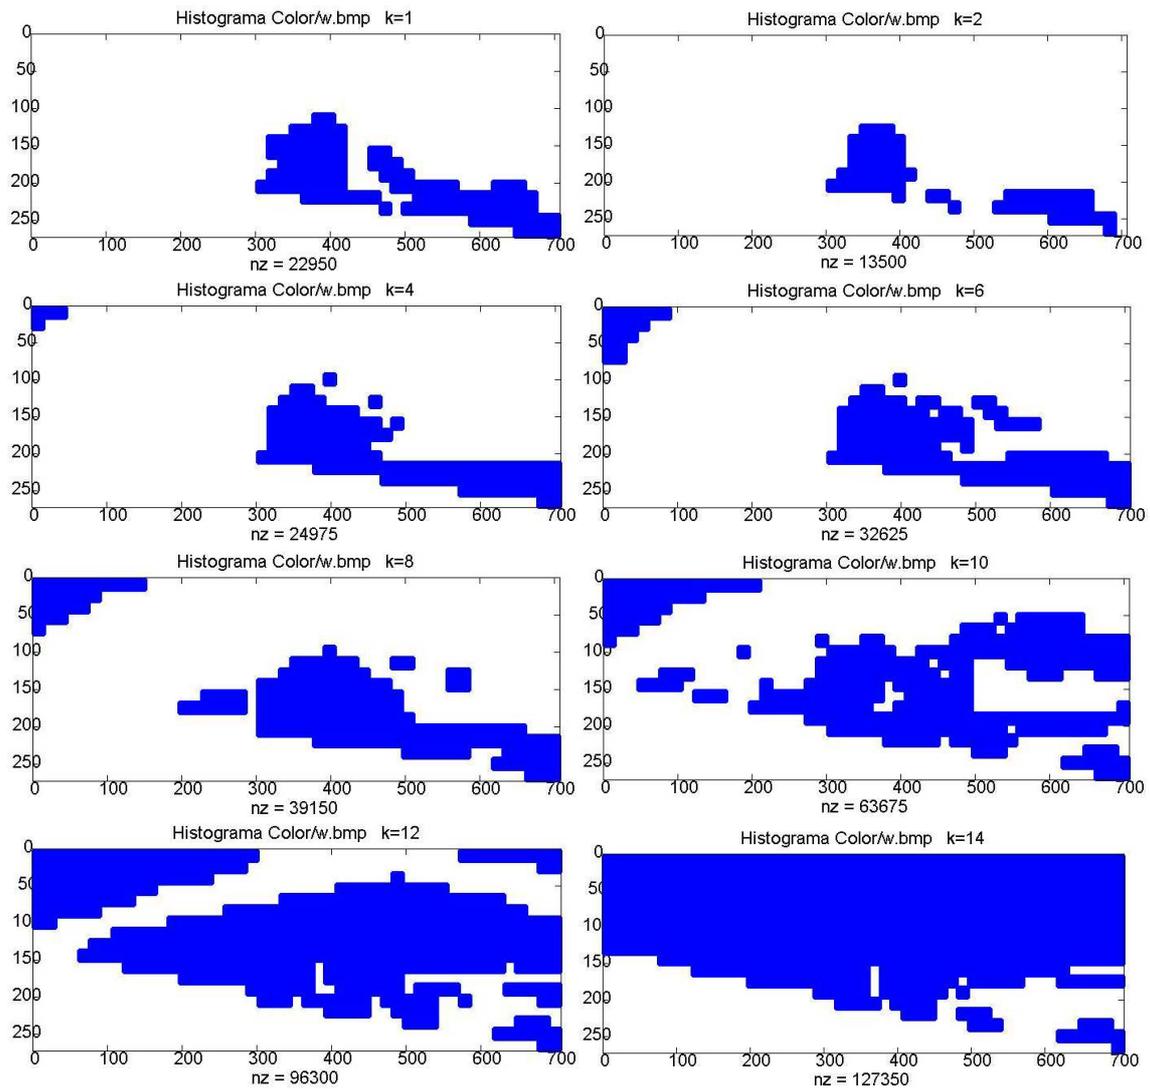


Figura 55. Evolución de los resultados del método de Histograma en color dependiendo del valor del parámetro “ k ”

Parámetro: 'tipoclasif'

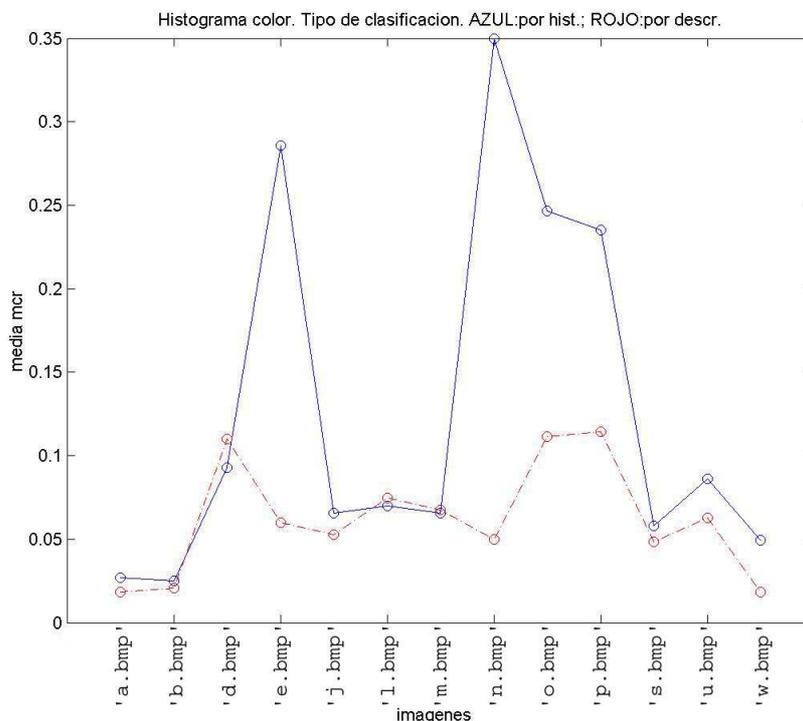


Figura 56. Histograma color. Tipo de clasificación.

AZUL (—): clasificación por histogramas;

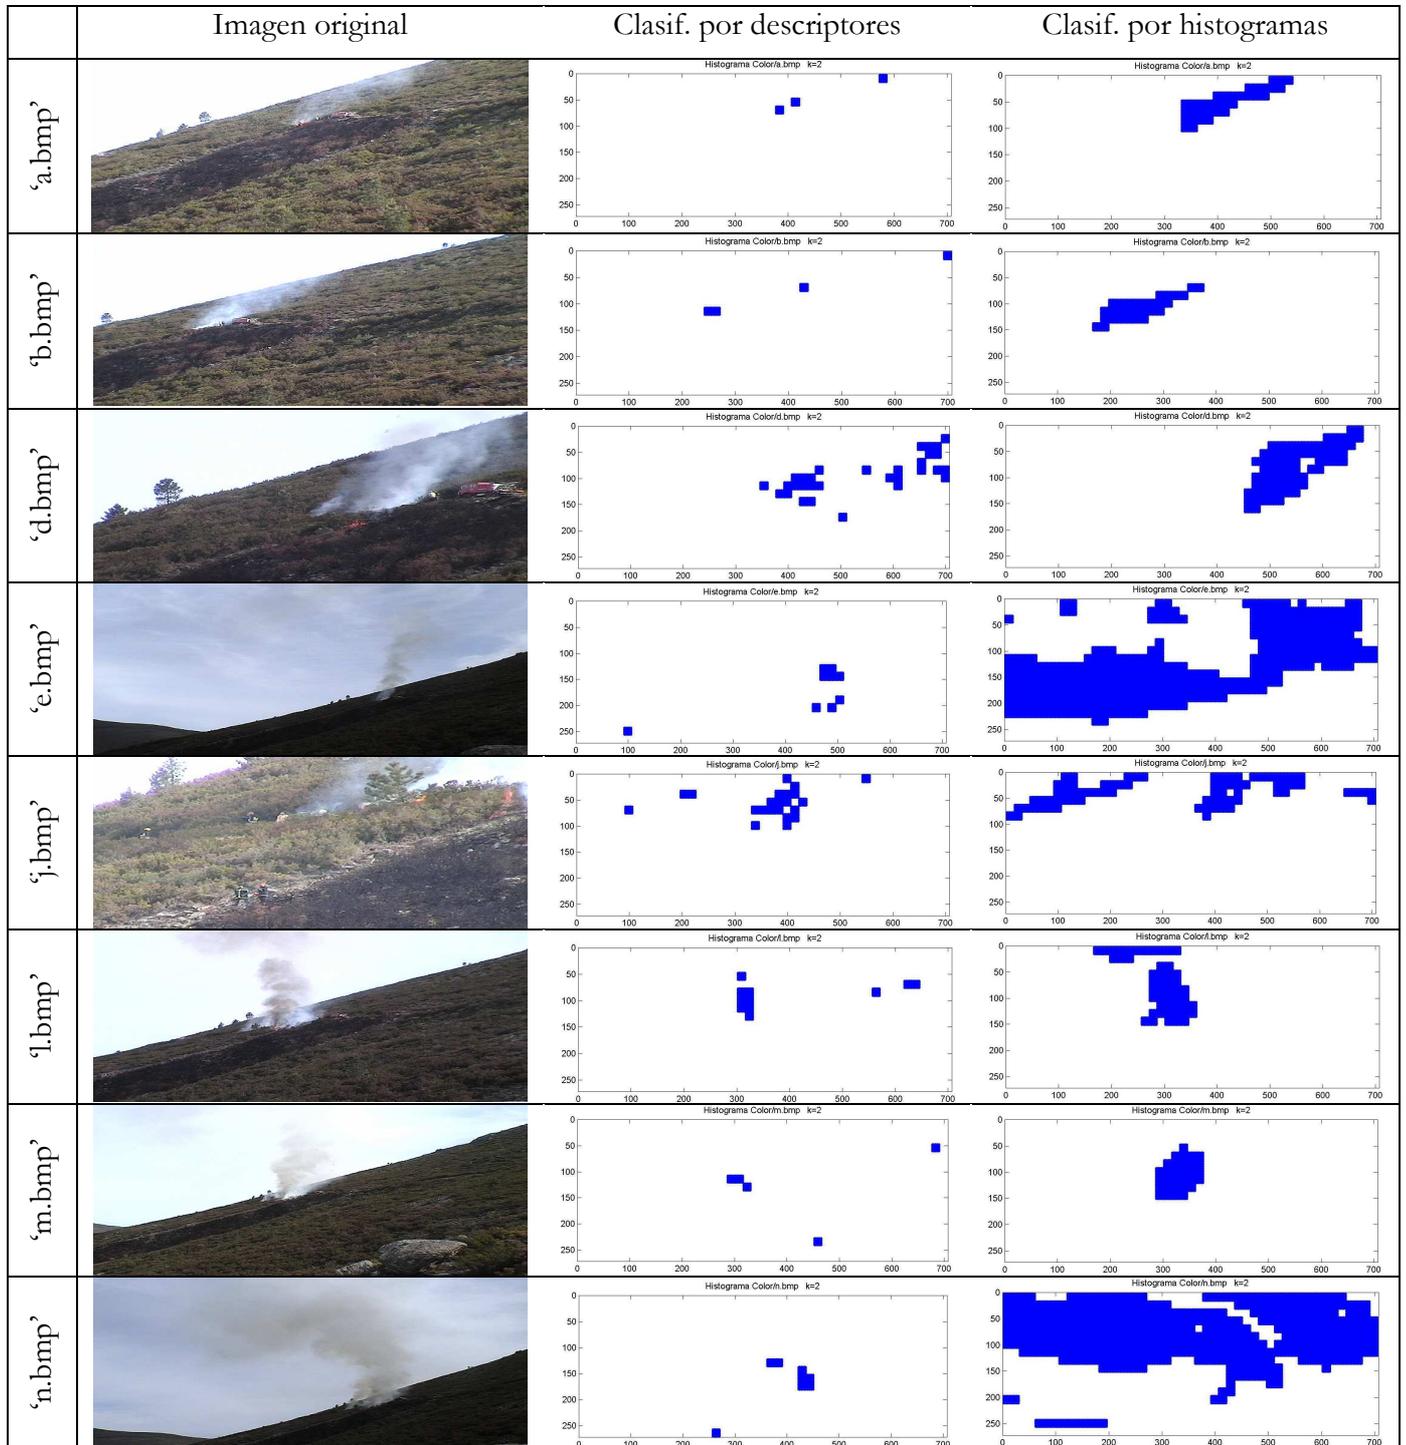
ROJO (- - -): clasificación por descriptores

Como ocurría con el método en blanco y negro, la clasificación por histogramas tiene el inconveniente de que confunde a veces el cielo con las nubes. Es importante decir que esta confusión se puede elegir con una selección de las muestras de la base de datos más exhaustiva, tomando más muestras de clase no humo, de este modo sólo en el caso de que haya humo realmente, la muestra se detectará como tal.

La clasificación por descriptores (figura 56) da mejores resultados en color que en blanco y negro como se puede observar en las segmentaciones de la tabla.

Igual que dijimos en el caso del histograma en blanco y negro, aunque en la gráfica del tipo de clasificación por histograma o por descriptores haya imágenes de con mayor tasa mcr con la clasificación por histogramas que con clasificación por descriptores la segmentación del

primero es mejor pues aunque detecte más cosas aparte del humo, éste lo detecta bien, que es uno de los objetivos que pretendemos de los métodos.



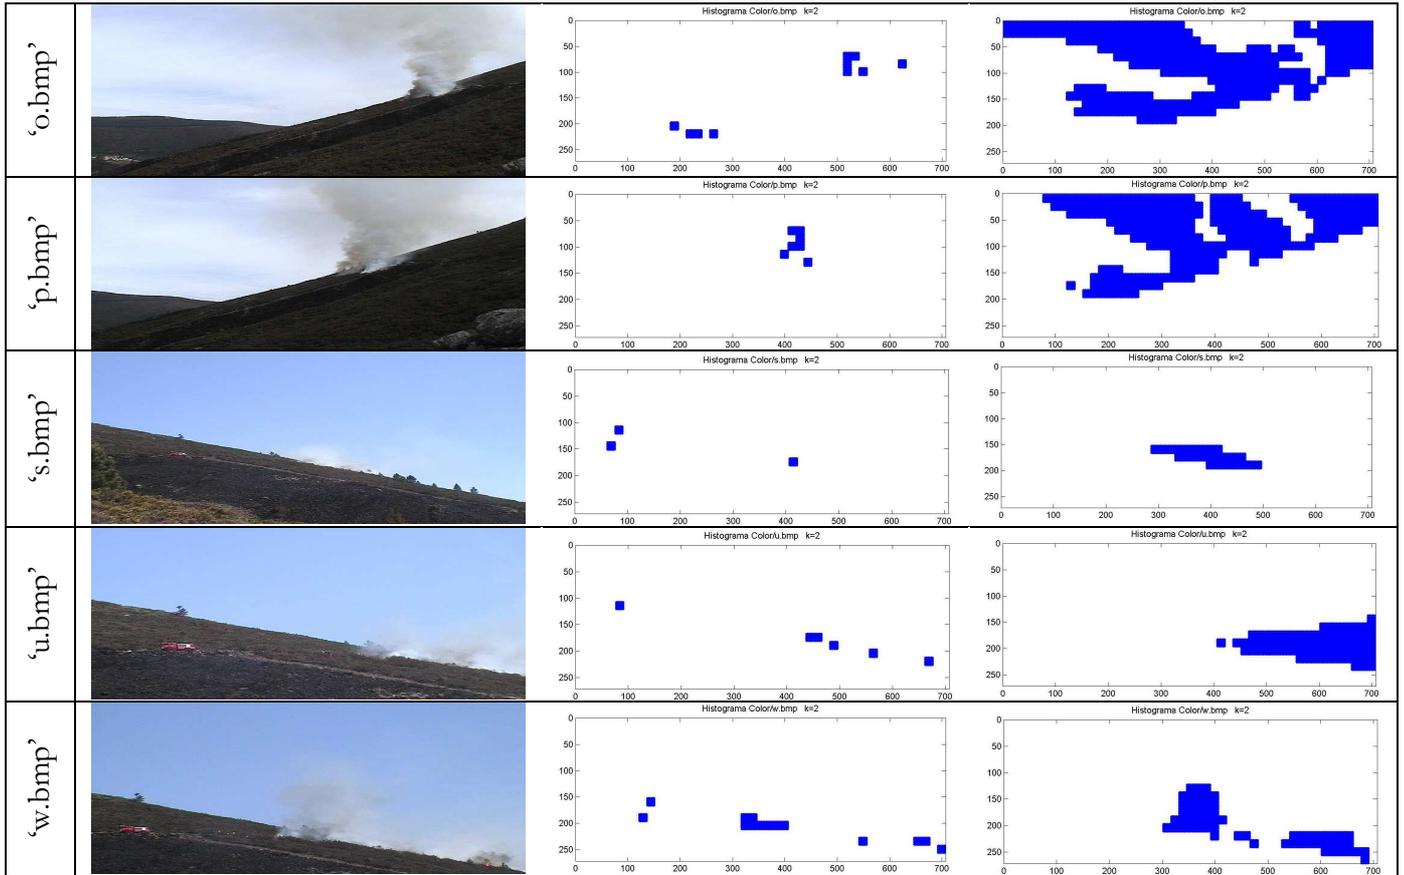


Tabla 15. Tabla que compara los resultados obtenidos mediante el método del histograma en color utilizando los tipos de clasificación por descriptores y por histograma.

- **Estudio de los parámetros de Co-ocurrencia en blanco y negro**

Parámetro: 'ventana'

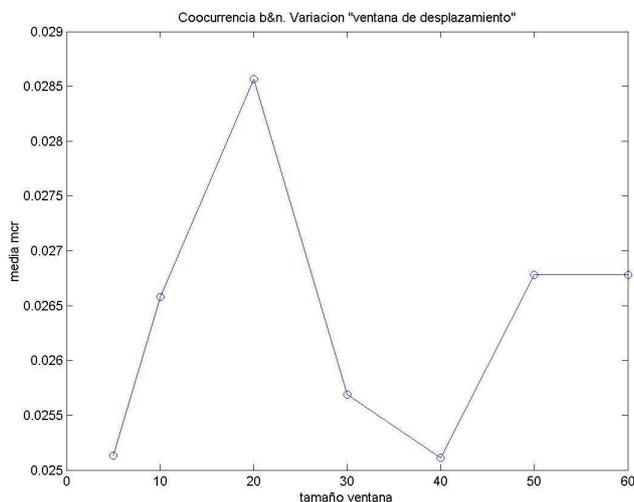


Figura 57. Coocurrencia b&n. Variación "Ventana de desplazamiento"

Las muestras de la base de datos tienen tamaño 40x40, que coincide con el tamaño de ventana que da menor tasa de error. Y conforme nos alejamos de este tamaño aumenta la tasa de error. Existe también un mínimo en 5 pero puede ser un caso particular para la imagen 'w.bmp' que hemos usado.

Parámetro: k (k-nearest neighbors)

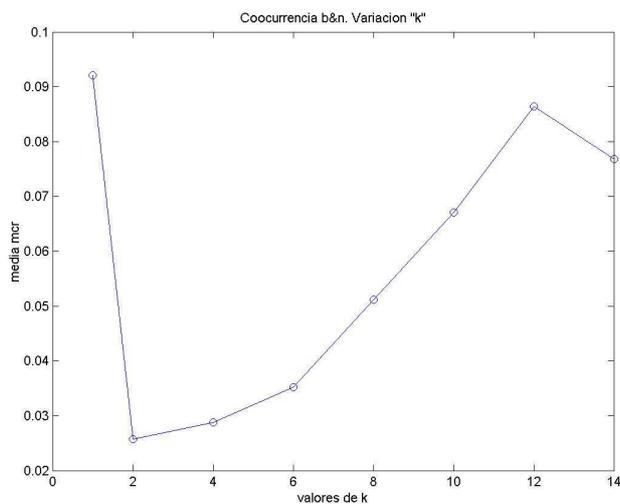


Figura 58. Coocurrencia b&n. Variación "k"

Para estudiar los valores de k damos valores desde $k = 1 \dots 14$. Viendo la gráfica de la figura 58 y las anteriores donde se han realizado pruebas con k , se puede deducir que para $k=1$, suele funcionar mal, pues toma los valores más altos de mcr . También se observa que el valor óptimo es $k = 2$ y que va aumentando el error conforme aumenta k .

Parámetro: 'tipoclasif'

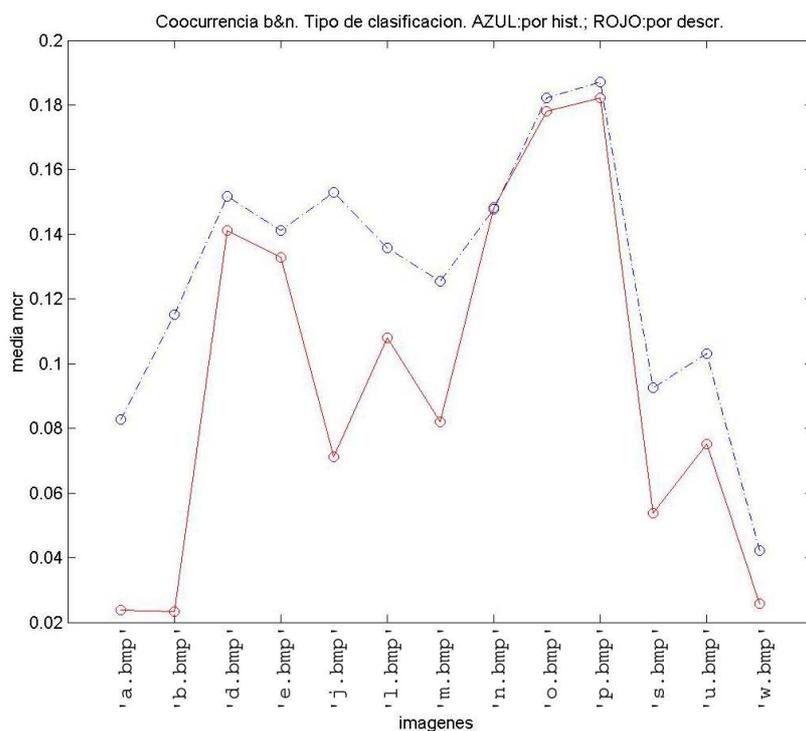


Figura 59. Cocurrencia b&n. Tipo de clasificación.
 AZUL (- - -): clasificación por histogramas;
 ROJO (—): clasificación por descriptores

Así como en el método de histograma daba mejor resultado la clasificación por histogramas que por descriptores, en el método de cocurrencia da mejor resultado la clasificación por descriptores. En la gráfica de la figura 59 se puede observar que en todas las imágenes la tasa de error cruzado es menor en el caso de la clasificación por descriptores que en el caso de la clasificación por histogramas.

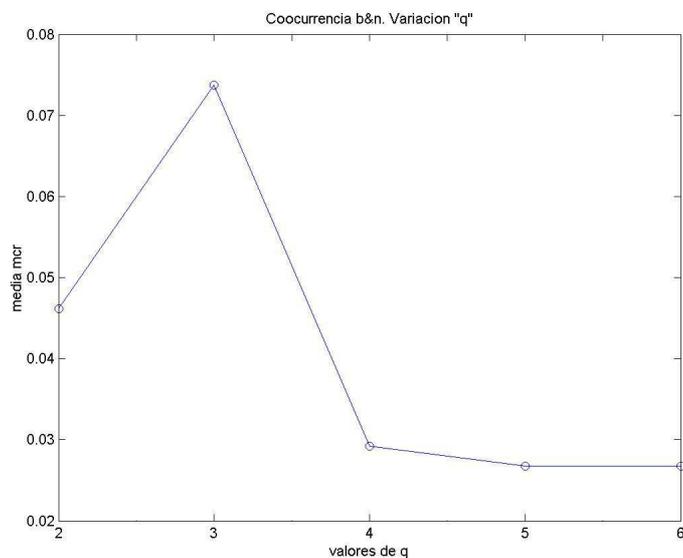
Parámetro: 'q'

Figura 60. Coocurrencia b&n. Variación "q"

Para hacer pruebas con este parámetro se ha tenido que ir calculando nuevos valores de la base de datos, pues el parámetro de la matriz de coocurrencia 'q' afecta al cálculo de la matriz, de los histogramas de la matriz y de los descriptores de manera importante.

La matriz de coocurrencia tiene tamaño 256x256, es decir, tantos valores como valores de intensidad pueda tomar un color. Ahora bien, el procesamiento de imágenes con este tamaño de matriz de coocurrencia es bastante lento por la cantidad de operaciones que se necesitan para hallar la matriz. Si además, contamos que hay que calcular esta matriz tantas veces como ventanas tome al recorrer la imagen se necesitaría mucho coste computacional lograr la segmentación de la imagen. Es por esto que es una práctica habitual en el método de la matriz de coocurrencia el reducir la matriz mediante un coeficiente de reducción 'q', que conceptualmente agrupa los niveles de intensidad de una imagen a un conjunto menor de niveles.

Los tamaños de la matriz en función del coeficiente "q" son:

si $q = 0 \rightarrow 256 \times 256$

si $q = 1 \rightarrow 128 \times 128$

si $q = 2 \rightarrow 64 \times 64$

si $q = 3 \rightarrow 32 \times 32$

- si $q = 4 \rightarrow 16 \times 16$
- si $q = 5 \rightarrow 8 \times 8$
- si $q = 6 \rightarrow 4 \times 4$
- si $q = 7 \rightarrow 2 \times 2$
- si $q = 8 \rightarrow 1 \times 1$

Tabla 16. Relación entre los valores del coeficiente “q” y las dimensiones de la matriz de coocurrencia

En la práctica, valores como $q=7$; $q=8$ son inútiles, por la poca información que contendrían.

Es interesante observar que para valores de q pequeños la tasa de error es más elevada que para valores de q intermedios. Para valores mayores de 4 la tasa de error permanece constante. En este estudio se ha tomado $q = 6$.

Parámetro: ‘dir_búsqueda’

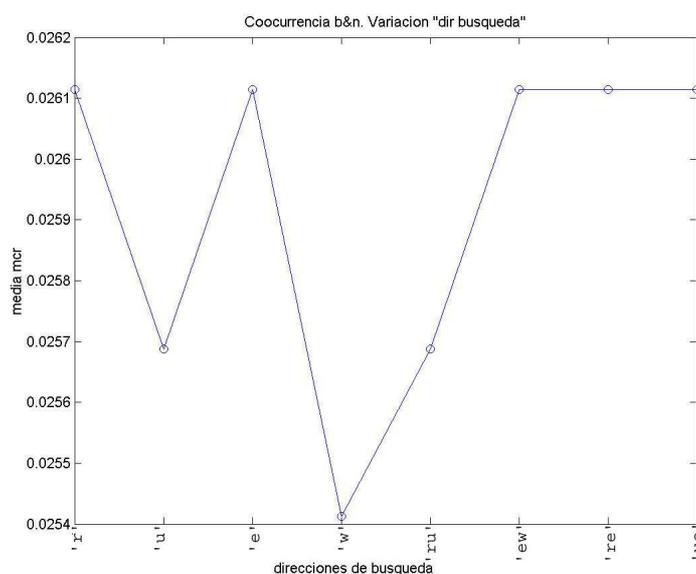


Figura 61. Coocurrencia b&n. Variación de la dirección de búsqueda en la matriz de coocurrencia

Se han probado distintas direcciones de búsqueda, aunque se podrían probar todo tipo de combinaciones: ‘rue’; ‘ewr’; ‘ruew’... La elección de este parámetro es uno de los inconvenientes del método de la matriz de coocurrencia, problema que no tenían otros métodos como el de la Simplified Texture Unit que toma píxeles en todas las direcciones.

La diferencia entre tomar unas direcciones u otras no es excesivamente grande. En el caso del humo la mejor dirección a tomar puede ser variable pues la dirección de la textura puede variar según el tipo de humo.

En la imagen que se ha utilizado para presentar esta gráfica la mejor dirección es la “noroeste”, aunque más adelante veremos como esta dirección deja de ser la mejor.

El significado de las letras es el que se muestra en el siguiente diagrama.

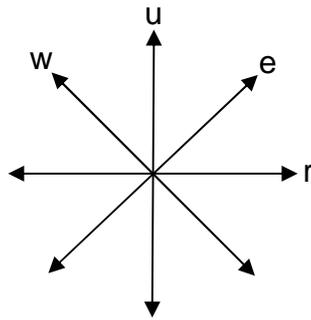


Figura 62. Posibles direcciones de búsqueda para la matriz de Co-ocurrencia. Cada dirección “w”, “u”, “e” y “r” utiliza los dos sentidos, de manera que la matriz es simétrica.

- **Estudio de los parámetros de Co-ocurrencia en color**

Parámetro: 'ventana'

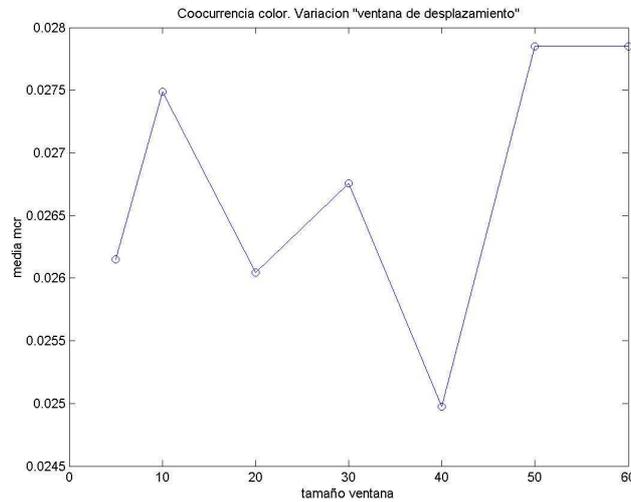


Figura 63. Coocurrencia color. Variación "ventana de desplazamiento"

Se observa que la menor tasa de error cruzado vuelve a obtenerse con un tamaño de ventana igual al tamaño que tienen las muestras de la base de datos.

Parámetro: k (k-nearest neighbors)

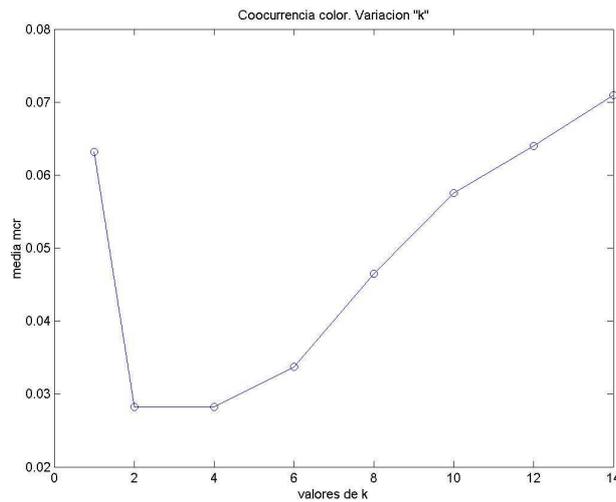


Figura 64. Coocurrencia color. Variación "k"

Para $k = 1$ se vuelve a obtener un alto valor mcr, después un mínimo en $k = 2$ y un aumento progresivo conforme aumenta la k .

Parámetro: 'tipoclasif'

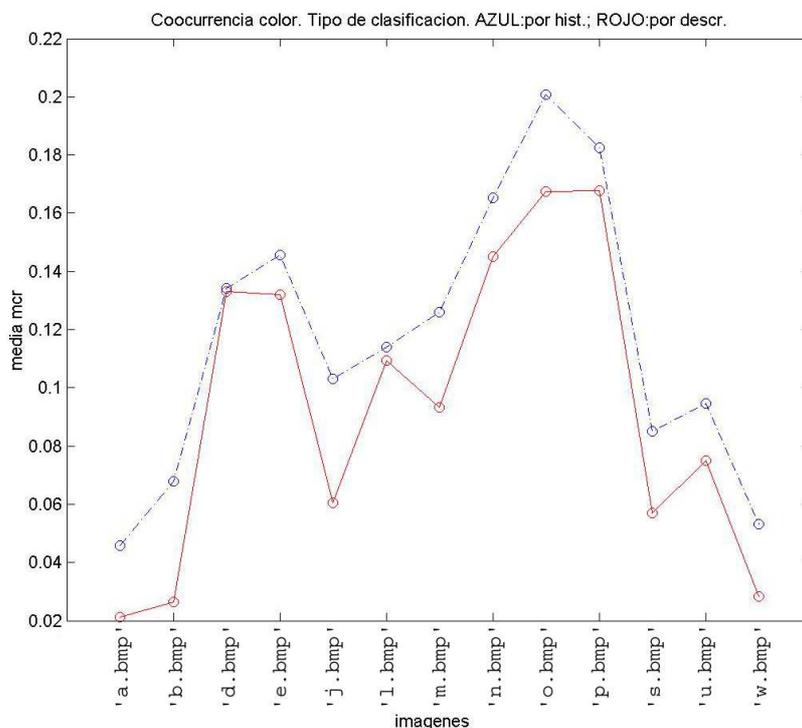


Figura 65. Coocurrencia color. Tipo de clasificación.

AZUL (- - -): clasificación por histogramas;

ROJO (—): clasificación por descriptores

En todas las imágenes la clasificación por descriptores da mejores resultados que la clasificación por histogramas. Para posteriores pruebas se va a usar la clasificación por descriptores.

Parámetro: 'q'

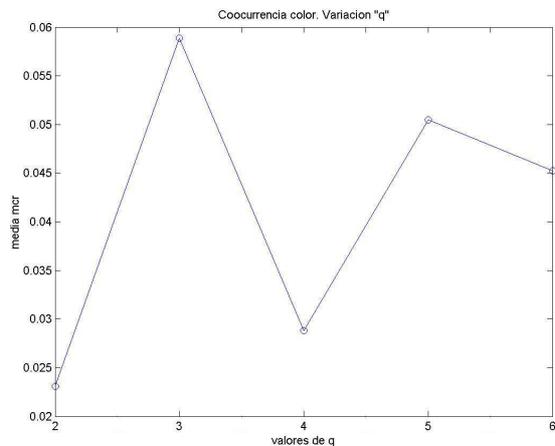


Figura 66. Coocurrencia color. Variación "q"

En el método a color, se observa comparándolo con el método en blanco y negro que para valores pequeños de 'q' se obtiene mcr baja. Pero atendiendo al coste computacional y a la tasa de error, el mejor valor sería $q = 4$. Nosotros hemos usado $q = 6$, que también obtiene un valor mcr bajo.

Parámetro: 'dir_búsqueda'

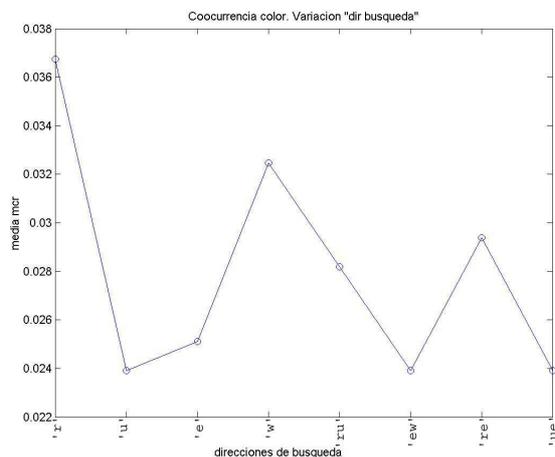


Figura 67. Coocurrencia b&wn. Variación de la dirección de búsqueda en la matriz de coocurrencia

Para este método, se obtienen otras direcciones distintas a la 'w' donde se obtienen mínimos de mcr. En este caso se obtienen para 'u', 'ew' y 'ue'.

- **Estudio de los parámetros de STU**

Parámetro: 'tipo'

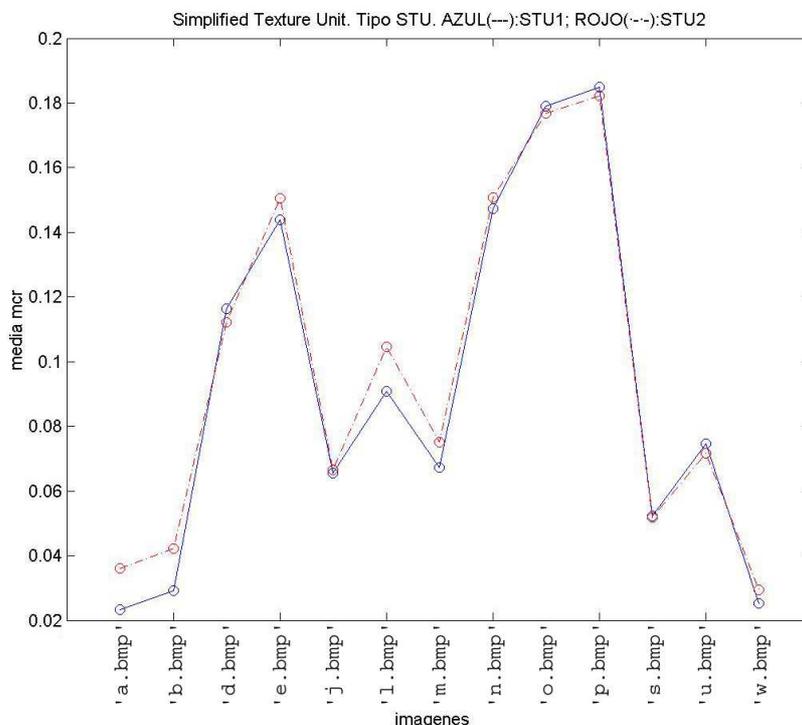


Figura 68. Unidad Simplificada de Textura, STU. Tasas de error MCR para cada imagen dependiendo del tipo de la STU: STU1 o STU2

Cuando se presentó en la parte teórica el método de la unidad simplificada de textura se dijo que había dos tipos de STU, la STU1 y la STU2, donde la primera toma los píxeles vecinos al píxel central en forma de cruz y la segunda toma los píxeles vecinos al píxel central en las direcciones diagonales.

Para obtener esta gráfica se han usado las 13 imágenes de humo que ya se han usado en otras ocasiones. Se puede observar que la STU1 tiene un mejor funcionamiento que la STU2, pues todos los valores de mcr son menores o iguales que si se usa el primer tipo. Es por esto que para posteriores usos de la STU se utilizará el primer tipo.

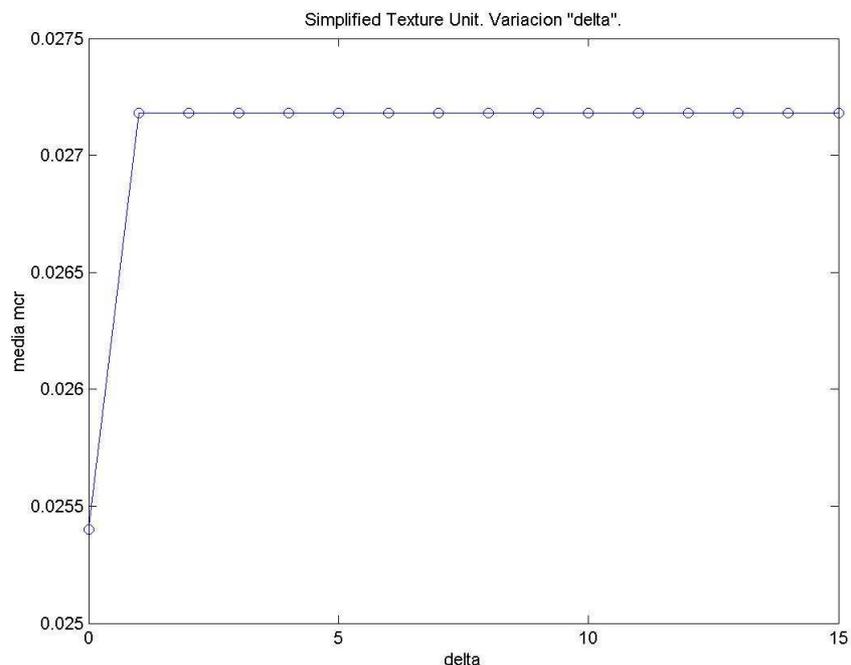
Parámetro: 'delta'

Figura 69. Unidad Simplificada de Textura, STU. Variación del parámetro "delta"

El parámetro 'delta' es la tolerancia a la hora de hallar la transformación de los píxeles vecinos. Es interesante observar que los resultados no dependen del valor de delta salvo que delta sea igual a cero, en cuyo caso el valor de la mcr se hace mínimo. Para esta delta la transformación que se realiza consiste en darle al píxel vecino valor 0 si es menor que el píxel central, valor 1 si el píxel es igual al píxel central, cosa que para el humo suele ser abundante, y valor 2 si el píxel es mayor.

También se deduce de esta gráfica que hay mucha información contenida en las imágenes de humo con pequeñas diferencias de un píxel a otro. O dicho de otro modo, que permitir algo de tolerancia en la STU hace perder mucha información de la imagen que se está clasificando.

Parámetro: 'ventana'

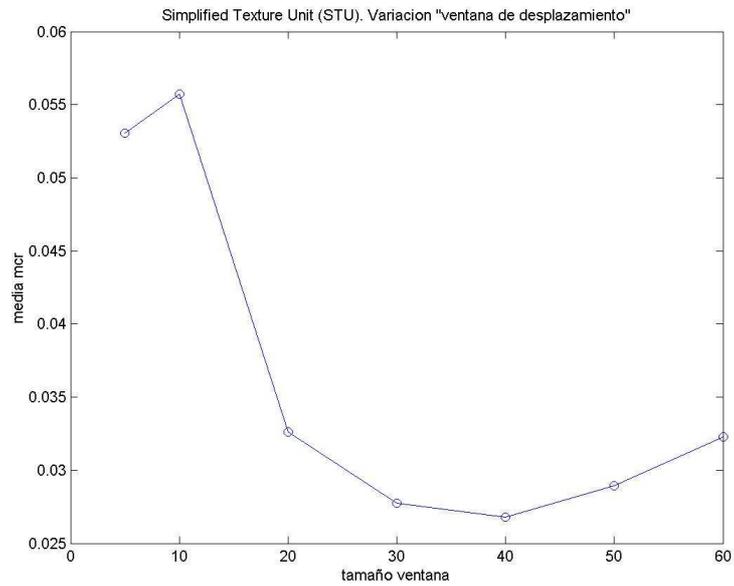


Figura 70. Unidad Simplificada de Textura, STU. Variación del tamaño de la ventana de desplazamiento

Más claramente se observa que es entorno al tamaño de las muestras donde se obtienen las menores tasas de error.

Parámetro: k

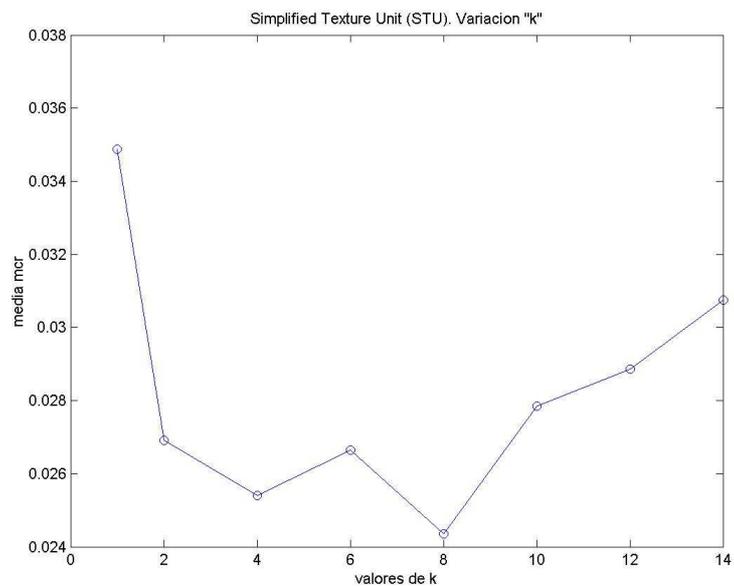


Figura 71. Unidad Simplificada de Textura, STU. Variación "k"

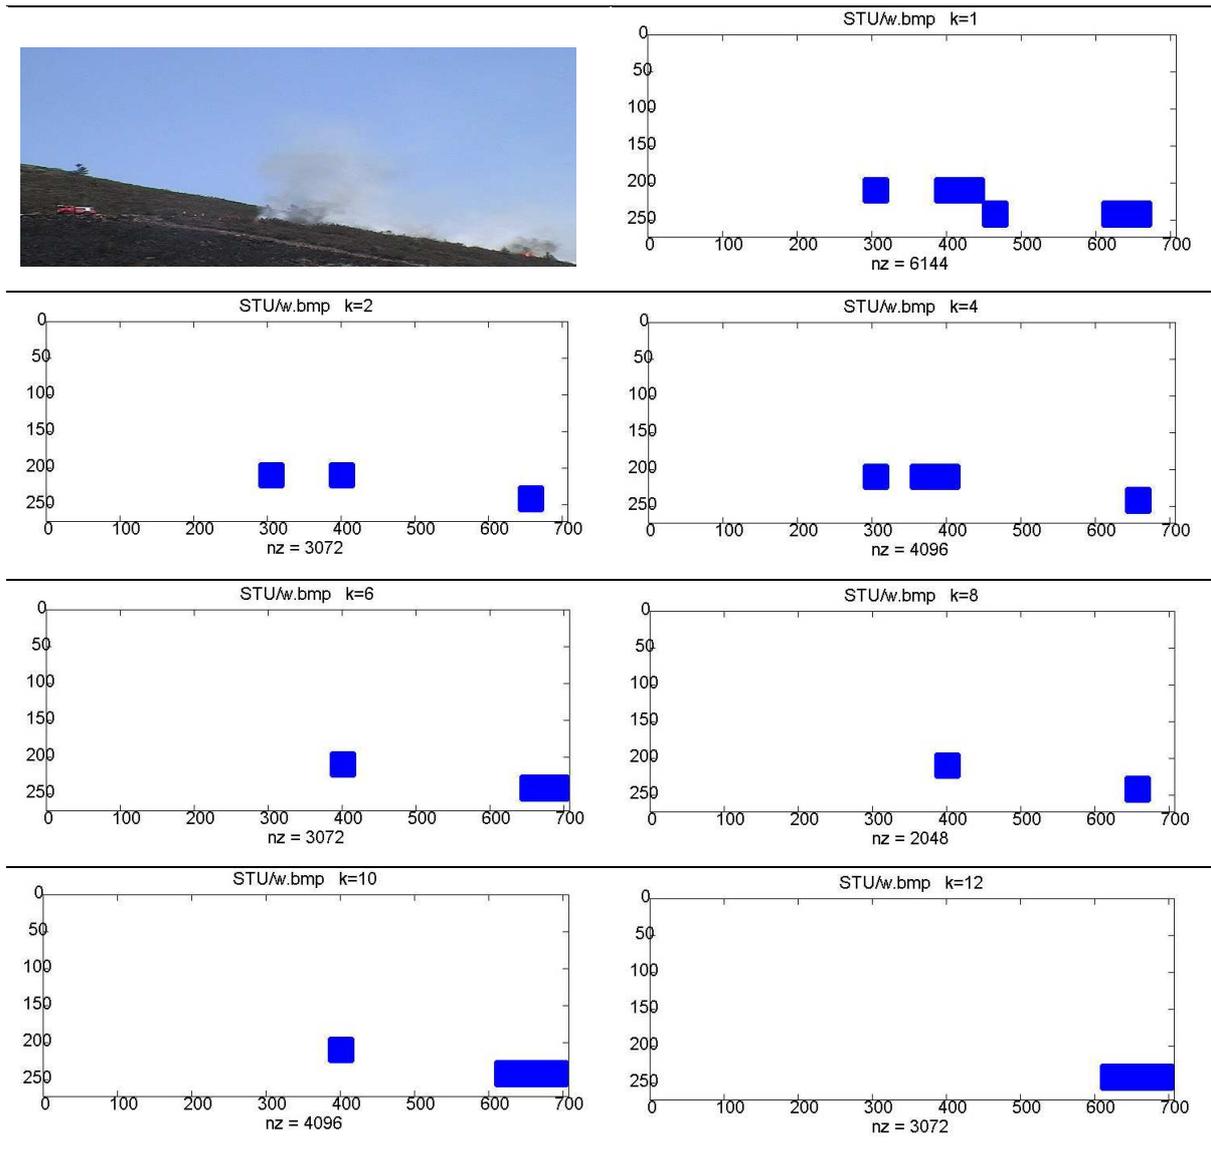


Tabla 17. Evolución de los resultados del método STU dependiendo del valor del parámetro “ k ”

4.3. Estudio comparativo entre los distintos métodos

Una vez que se han estudiado los parámetros de cada método y se han escogido aquellos que ofrecen mejores resultados, se va a realizar un estudio comparativo de los métodos entre ellos.

Este apartado es el resultado final del trabajo que se ha ido presentando a lo largo de este documento. Como se dijo al principio, en la clasificación de imágenes de textura existen

distintos métodos, bien basados en estadísticos de primer orden o bien de segundo orden. El funcionamiento de cada uno es distinto y ofrece resultados que si bien tratan de lograr un único objetivo, llegan por distintos caminos y consiguiendo resultados distintos pero con una correlación elevada.

A la hora de hacer una valoración de los resultados de los métodos se va a realizar mediante la tasa media de error cruzado (MCR) que hace uso del algoritmo KNN (k-nearest neighbors).

Teniendo en cuenta cuáles son los objetivos que se están buscando no vamos a tener excesivamente en cuenta que la segmentación de las imágenes por los distintos métodos incluya por error elementos de la imagen que no sean humo. Esto es así porque la clasificación por textura se puede usar conjuntamente con otros métodos tales como detectores de humo por movimiento, por descriptores de color, etc. Por tanto, se fijará la atención en que un método detecte el humo en las máximas ocasiones posibles.

Antes de presentar los resultados obtenidos con cada método se va a realizar una breve explicación de los algoritmos usados para la clasificación de las muestras de la imagen.

- **Algoritmo KNN (k-nearest neighbor algorithm)**

El algoritmo KNN es el que utilizamos para decidir de qué clase es una determinada muestra.

Para implementar el algoritmo KNN se ha formado se forma una base de datos con muestras de diferentes clases. Estas muestras, como es el caso de este proyecto, pueden ser imágenes de muestra de las que se han extraído unos descriptores que forman un espacio de muestras. En este espacio está localizada cada muestra de la base de datos. El número de clases es indefinido. Pues bien, dada otra muestra distinta de las de la base de datos el algoritmo KNN decide a qué clase pertenece.

La muestra de entrenamiento (training example) se mapea en el espacio de muestras hallando los descriptores de esa muestra según el método que se desee (i.e. descriptores de histograma, de matriz de coocurrencia, del método STU, etc).

El espacio de muestras está dividido en regiones según los tipos de clase contenidas en la base de datos. Un punto del espacio es asignado a la clase c si esta clase es la que tiene más frecuencia de entre las k muestras más cercanas al punto. Normalmente para medir la distancia se utiliza una medida de la distancia euclídea.

Para programar el algoritmo tan sólo hay que tener almacenados vectores de características o descriptores con etiquetas de las clases a las que pertenecen. Para clasificar una muestra de la que se desconoce la clase se calcula la distancia a todos los vectores almacenados y se escogen los k vectores más cercanos. Se predice que la muestra desconocida pertenece a la clase más numerosa dentro del conjunto de los k vectores más cercanos.

La mejor elección del valor de k depende de los datos; normalmente, valores grandes de k reducen el efecto de ruido en la clasificación, pero distorsionan los límites entre clases distintas. Un buen valor de k se puede escoger utilizando algún algoritmo de optimización de parámetros, por ejemplo, la validación cruzada que se ha realizado en el apartado anterior para obtener el valor de k que da menor tasa de error cruzado. El caso especial en la que se predice que la clase de una muestra desconocida es la misma que la de la muestra más cercana (i.e. cuando $k = 1$) se llama algoritmo del vecino más cercano.

El algoritmo KNN es fácil de implementar, pero tiene un coste computacional elevado, especialmente cuando el tamaño de la muestras de la base de datos aumentan. Aun así, es algoritmo ofrece unos resultados muy consistentes. Cuando la cantidad de datos se acerca al infinito, el algoritmo garantiza un rendimiento en la tasa de error no peor que dos veces la tasa de error de Bayes (la mínima tasa de error posible dada una distribución de datos). E incluso, para algunos valores de k (cuando el valor de k incrementa en función del número de muestras de la base de datos) el algoritmo acerca su tasa de error a la tasa de error de Bayes.

- **Tasa de Error Cruzado (Misclassification Rate, MCR)**

Para realizar una comparación entre distintos métodos que han tratado de obtener un mismo resultado, se puede utilizar el método de validación cruzada que da como resultado una tasa de error cruzado.

Este método es muy utilizado en muchos campos como la medicina, la bioingeniería, biometría, etc. Entre otras ventajas permite comparar métodos sin necesidad de segmentar manualmente las regiones “correctas”, ya que unos métodos corrigen a otros. Es un algoritmo automático de evaluación para distintos métodos que funcionan independientemente.

La tasa de error cruzado es una medida que indica el porcentaje de falsos negativos presentes en un modelo. El modelo óptimo entre los que estudien mediante la media MCR sería aquel que tuviese el valor MCR más pequeño.

La implementación del método consiste en una comparación cruzada de las distintas segmentaciones de una imagen a partir del algoritmo KNN según cada método que se esté estudiando. Supongamos que tenemos n métodos y se desea saber cuál es el método que da mejores resultados sin necesidad de realizar una segmentación manual de la imagen. Para ello se toma una de las imágenes segmentadas y se comprueba píxel a píxel si coincide con los píxeles paralelos de las imágenes segmentadas por los otros métodos. Esto dará como resultado una nueva imagen donde cada píxel contiene información de cuántos métodos están de acuerdo con lo que el primer método había elegido, en que el píxel dado estaba clasificado correctamente. Una vez normalizada esta matriz por el número de métodos y el número de píxeles de la imagen, se obtiene que si la segmentación fuese perfecta al haber obtenido los mismos resultados que todos los demás métodos, la suma de todos los valores de la matriz daría 1. En el caso de que hubiese discordancias la suma de los elementos de la matriz sería menor que 1. Este valor es la probabilidad de acierto del método del que se esté valorando su eficacia. Pues bien, al restar 1 menos la probabilidad de acierto obtenemos la tasa de error cruzado o misclassification rate, MCR.

Este método es el que se ha utilizado para valorar los distintos métodos propuestos en este trabajo.

Si bien, existen algunos inconvenientes en la validación cruzada y que se pueden denominar “malos aliados”. En el caso en el que se estudie la validación cruzada entre pocos métodos, puede ocurrir que si la mayoría segmentan la imagen de un modo ineficaz tiren hacia abajo de otros métodos que de por sí sean más válidos.

4.3.1. Resultados del estudio con la primera base de datos

Vamos a realizar dos baterías de pruebas con las mismas imágenes pero modificando la base de datos de muestras. Diciéndolo de otro modo, incluyendo muestras en el espacio de muestras de manera que se hagan más nítidas las fronteras entre las dos clases de humo y de no-humo.

Se ha realizado una selección de fotografías de humo, sacadas de las quemas de Gestosa, que son las siguientes.



a.bmp



b.bmp



d.bmp



e.bmp



j.bmp



l.bmp

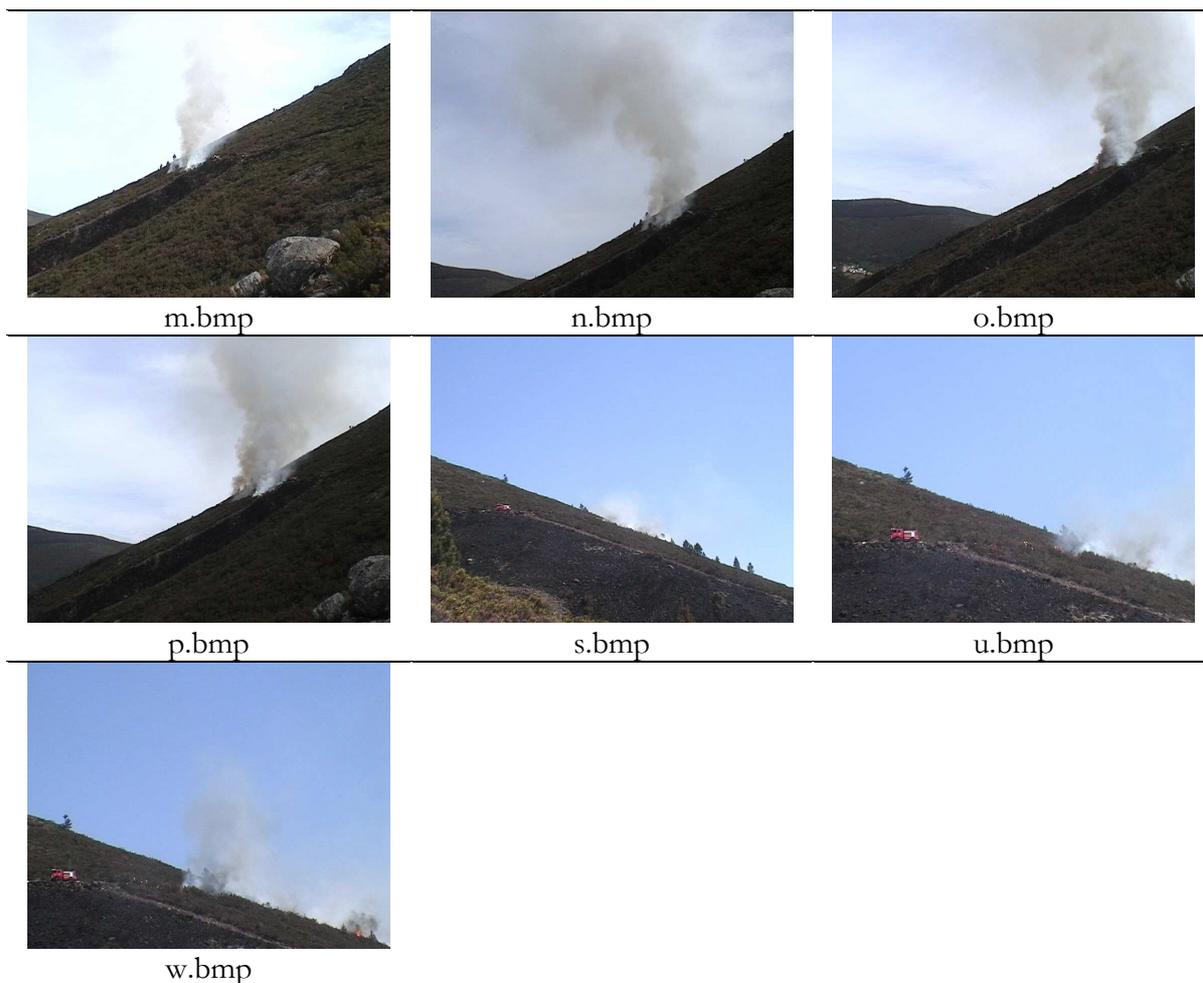


Figura 72. Batería de imágenes de prueba

Estas imágenes se van a segmentar según cinco métodos, tratando de clasificar ventana a ventana si pertenece a la clase humo o a la clase no-humo. Los métodos que se han usado son los que ya se han comentado anteriormente.

Los resultados que se presentan en la figura 73 son un gráfico donde para cada imagen se da el valor de la tasa de error cruzado y una tabla donde se muestran para cada imagen la segmentación que se produce por cada método.

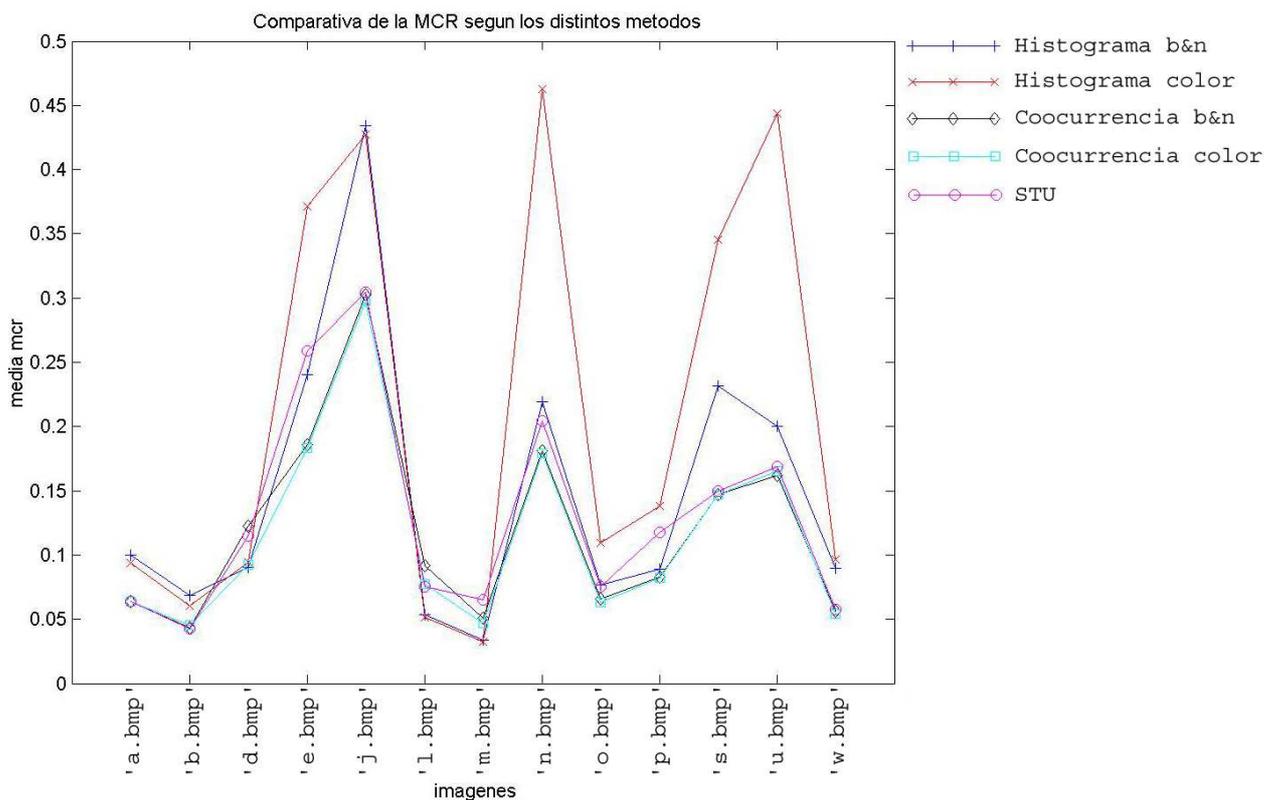


Figura 73. Comparativa de los valores de la tasa MCR para cada imagen de prueba y según cada método

Algunas conclusiones que se deducen de esta gráfica son:

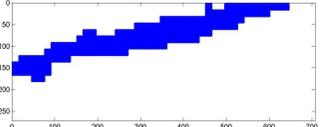
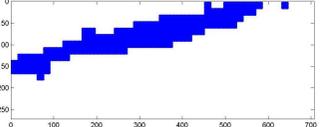
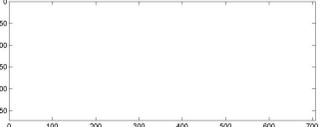
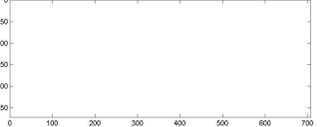
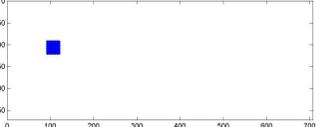
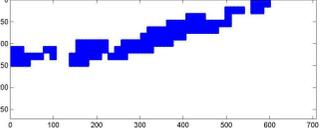
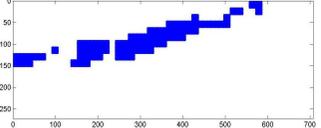
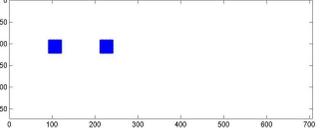
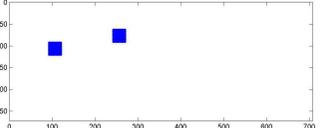
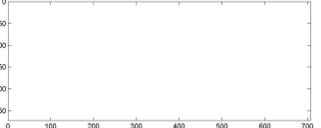
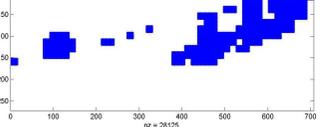
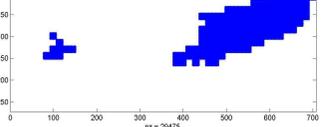
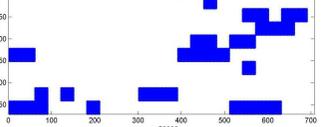
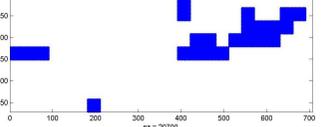
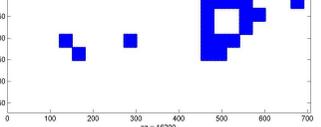
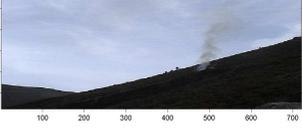
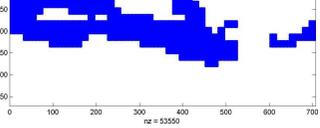
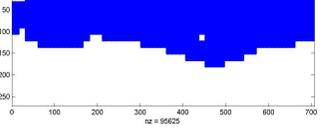
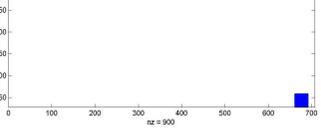
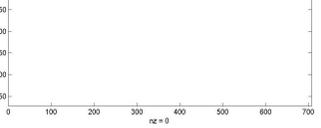
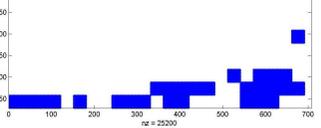
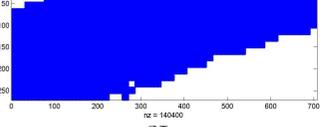
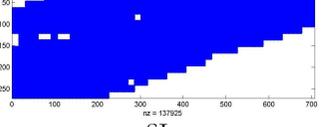
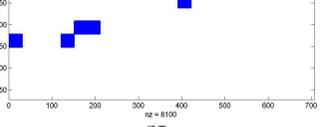
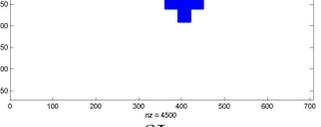
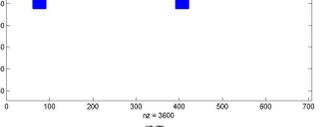
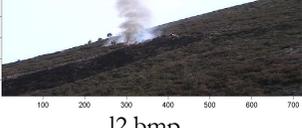
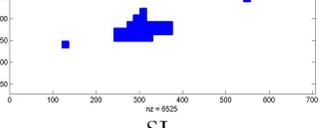
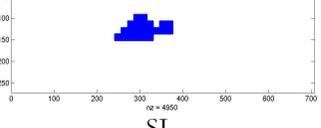
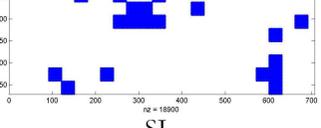
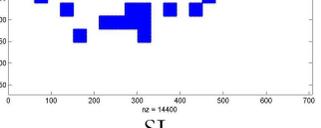
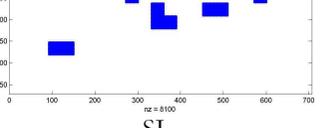
- Cada imagen tiene un nivel medio de tasa de error cruzado distinto, esto es así pues cada imagen de humo es distinto para un espacio de muestras fijo.
- El método del histograma, tanto a color como en blanco y negro se separa de los valores normales, aumentando la media mcr. Observando las imágenes de que se trata se observa que son imágenes en las que predominan nubes grisáceas que confunde con el humo. Esto hace que la segmentación difiera en gran medida del resto de segmentaciones realizadas por los demás métodos.
- Realizando un estudio más detenido de la gráfica se observa que el método que en más ocasiones tiene mayor tasa de error es el método del histograma en color (7 veces). El siguiente método es el del histograma en blanco y negro, el tercero el método STU, el

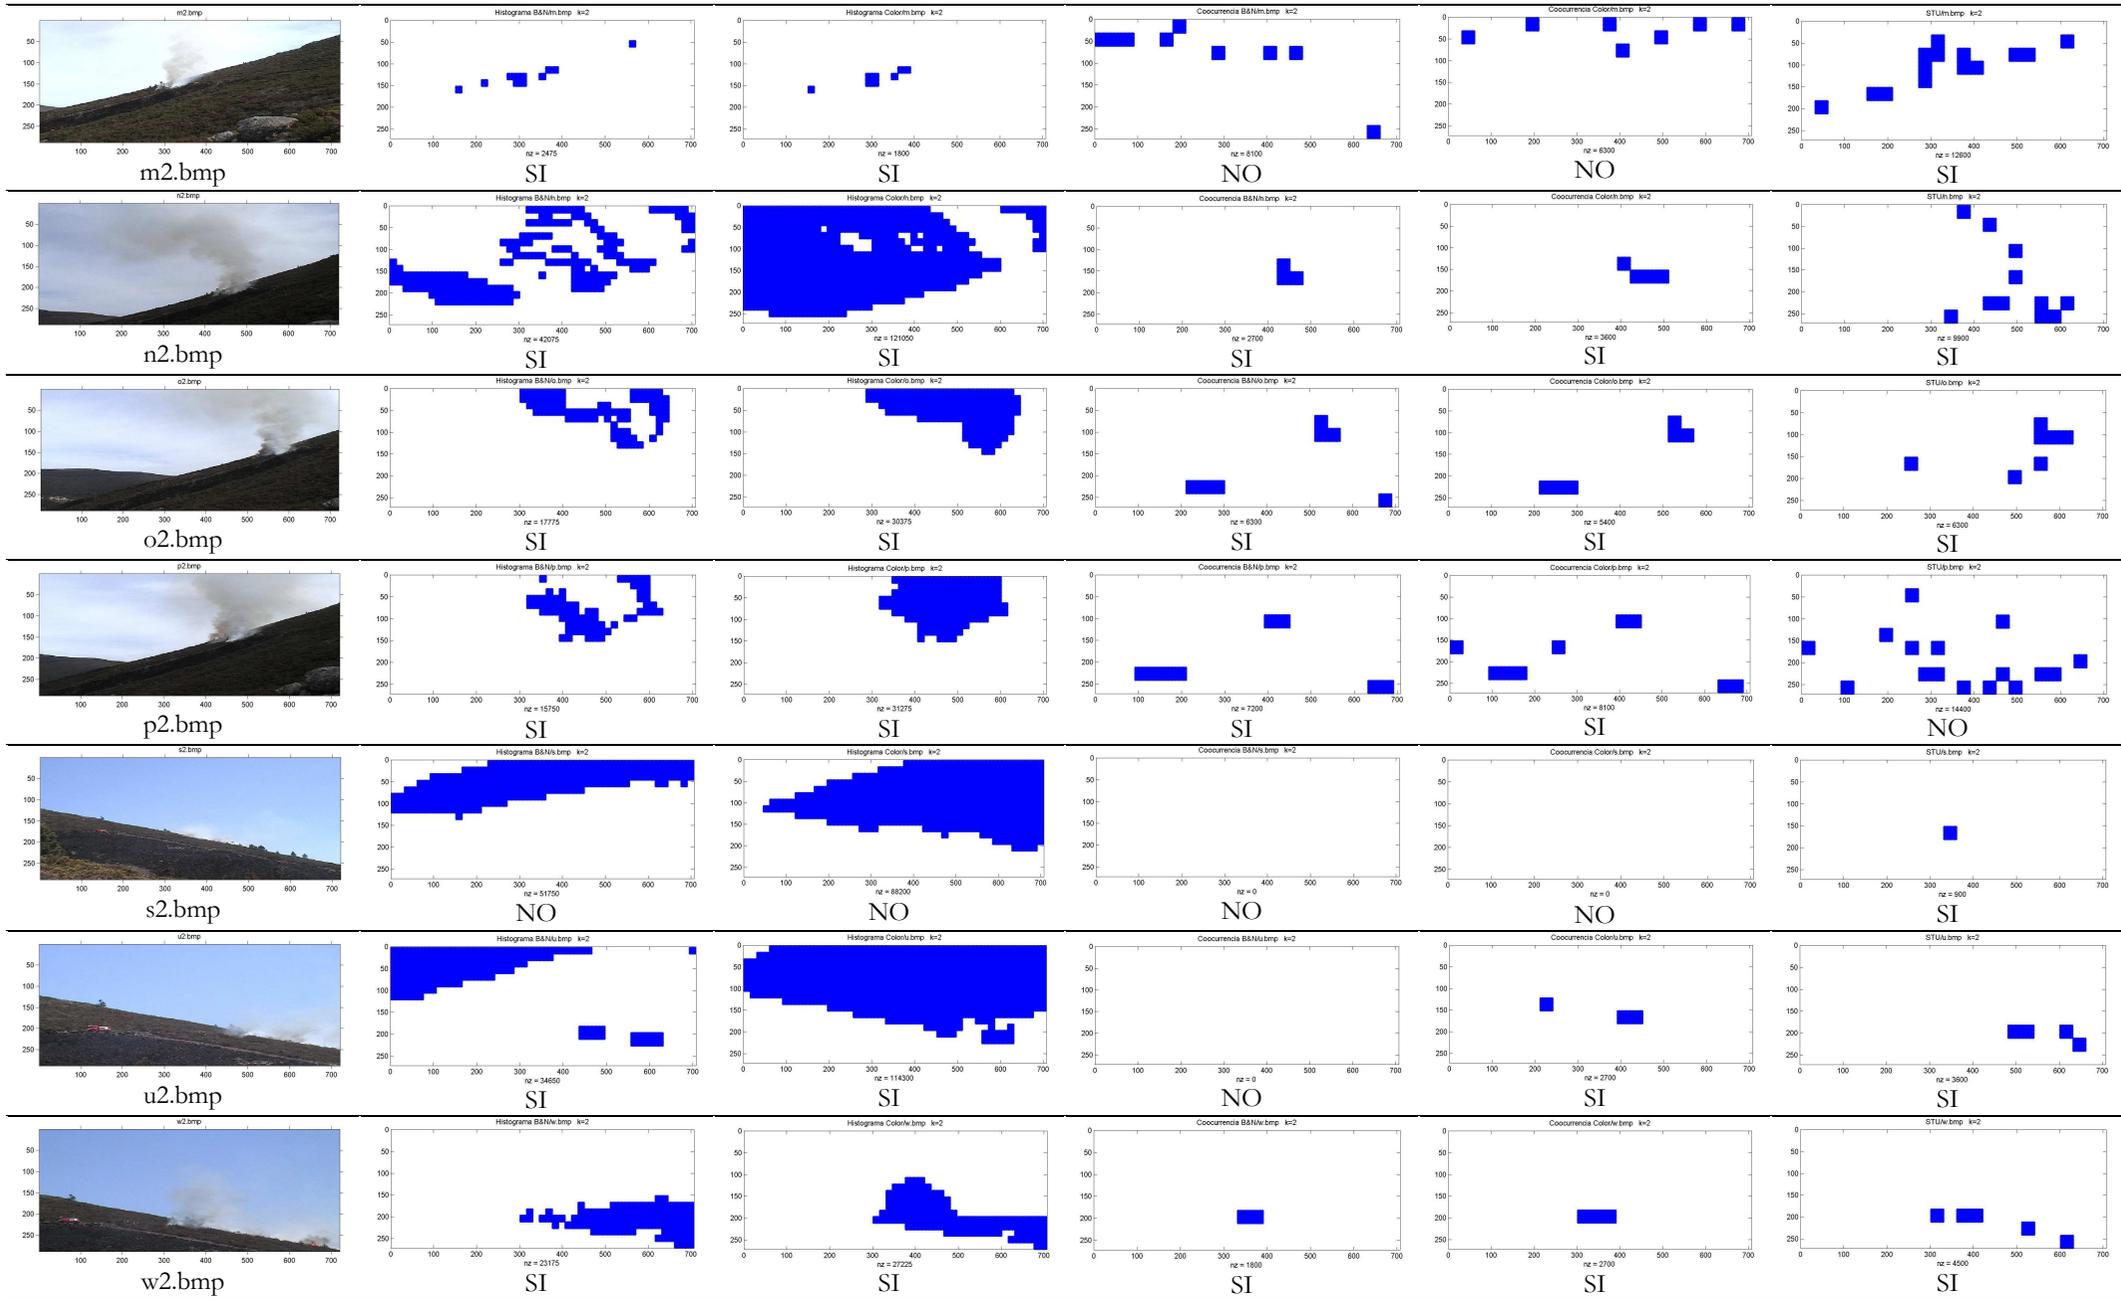
cuarto, el método de coocurrencia en blanco y negro, y la que más veces tiene un menor valor mcr es el método de coocurrencia en color que otras 7 veces consigue la menor tasa de error cruzado.

A continuación se presenta la tabla con los resultados de las imágenes segmentadas. Dejando de lado la media MCR, y atendiendo a los métodos que subjetivamente detectan el humo aunque detecten también otras zonas por error, se ha obtenido un porcentaje de acierto en la detección para cada método:

Histograma en blanco y negro	→ 92.3% de acierto (12 de 13 imágenes)
Histograma en color	→ 92.3% de acierto (12 de 13 imágenes)
Coocurrencia en blanco y negro	→ 61.5% de acierto (8 de 13 imágenes)
Coocurrencia en color	→ 69.2% de acierto (9 de 13 imágenes)
STU	→ 69.2% de acierto (9 de 13 imágenes)

Tabla 18. Pruebas de detección de humo de 13 imágenes teniendo como base de datos muestras de la imagen "w.bmp"

NOMBRE Porcentaje detección →	HISTOGRAMA B&N 12/13 → 92.3%	HISTOGRAMA COLOR 12/13 → 92.3%	COOCURRENCIA B&N 8/13 → 61.5%	COOCURR. COLOR 9/13 → 69.2%	STU 9/13 → 69.2%
 a2.bmp	 SI nz = 31275	 SI nz = 29025	 NO nz = 0	 NO nz = 0	 NO nz = 900
 b2.bmp	 SI nz = 19800	 SI nz = 17325	 SI nz = 1800	 SI nz = 1800	 NO nz = 0
 d2.bmp	 SI nz = 28125	 SI nz = 29475	 SI nz = 28500	 SI nz = 20700	 SI nz = 16200
 e2.bmp	 SI nz = 53550	 SI nz = 54525	 NO nz = 900	 NO nz = 0	 NO nz = 25200
 j2.bmp	 SI nz = 140400	 SI nz = 137925	 SI nz = 8100	 SI nz = 4500	 SI nz = 25200
 l2.bmp	 SI nz = 6525	 SI nz = 4550	 SI nz = 18900	 SI nz = 14400	 SI nz = 6100



4.3.2. Resultados del estudio con la base de datos ampliada

Con la segunda base de datos se ha pretendido observar los cambios que se producen al aumentar los elementos del espacio de muestras con vistas a la clasificación de muestras de un modo más eficaz.

Se puede observar cómo se van a producir cambios relevantes en los resultados de los métodos, sobretodo en la exactitud de la segmentación de las imágenes. Ahora se observarán unos límites mucho más precisos.

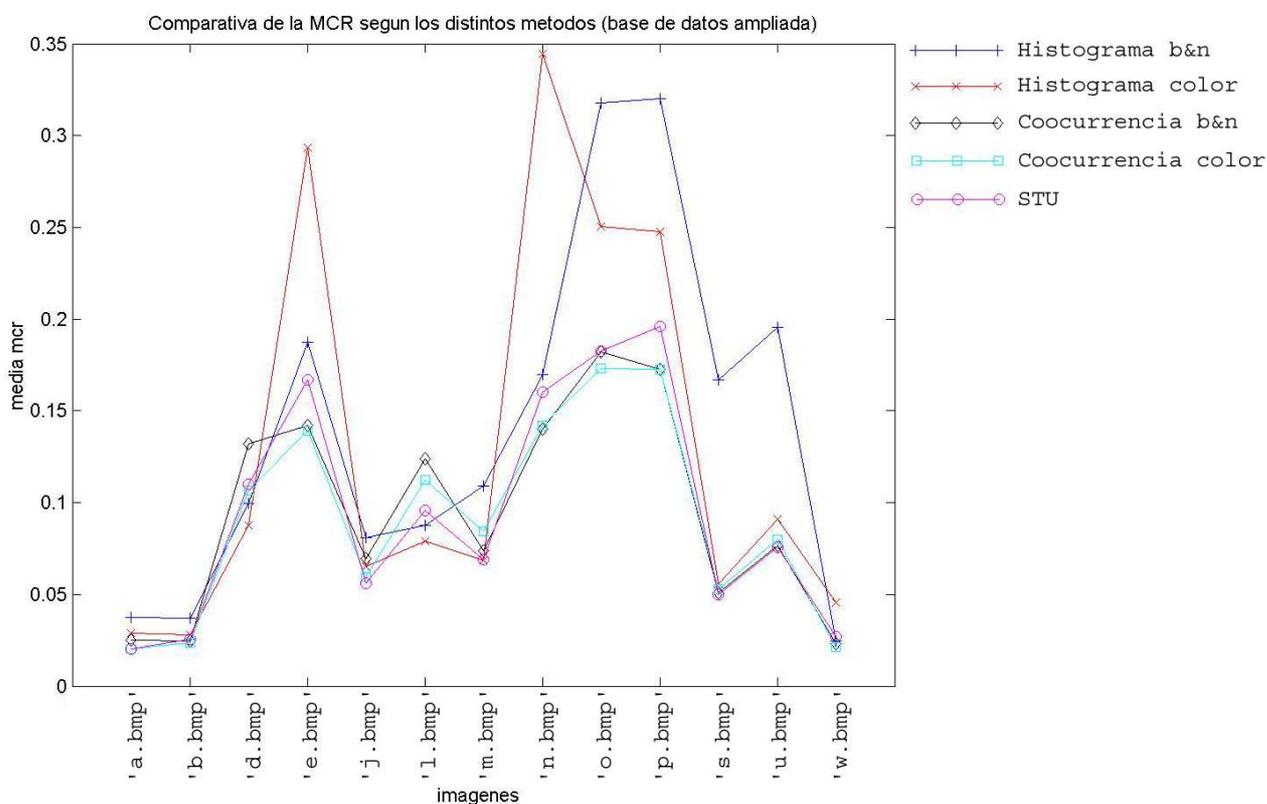


Figura 74. Comparativa de los valores de la tasa MCR para cada imagen de prueba y según cada método

Se puede ver en esta gráfica que los valores de las tasas de error están más distantes unas de otras para una misma imagen. Aun así, realizando de nuevo estadísticas de las tasas que se

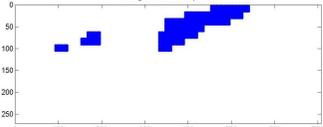
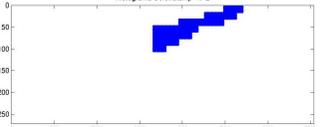
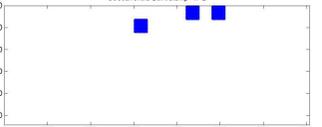
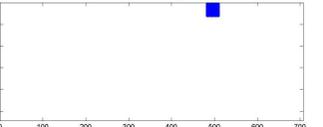
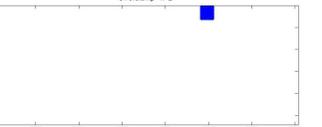
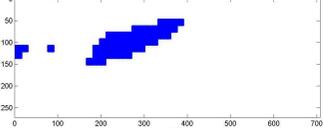
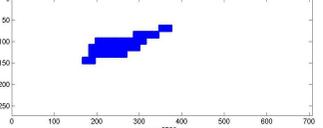
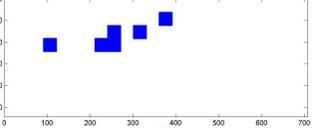
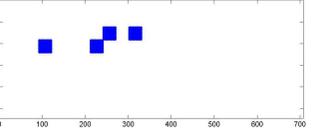
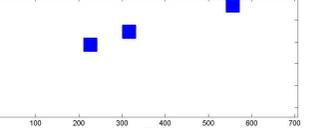
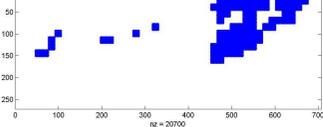
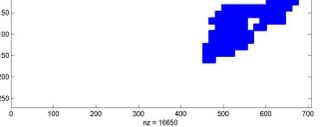
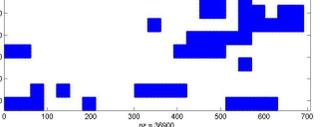
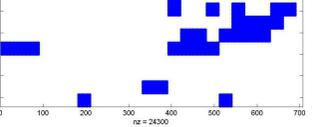
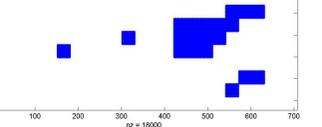
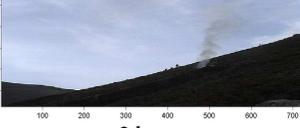
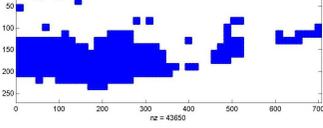
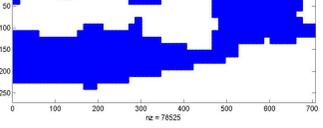
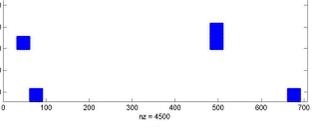
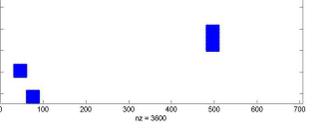
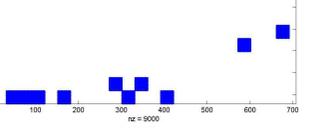
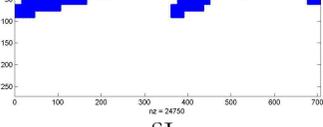
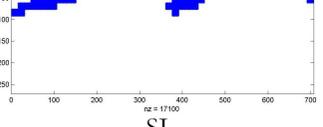
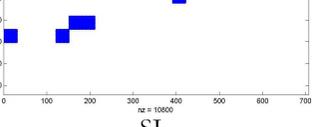
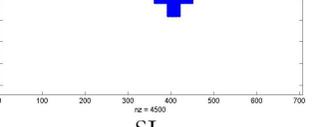
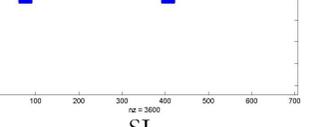
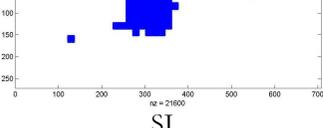
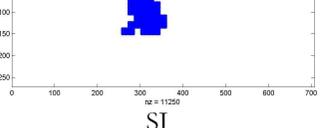
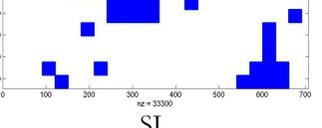
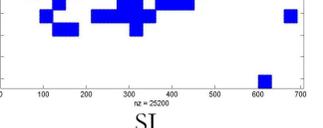
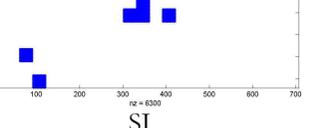
obtienen para cada método y para cada imagen se vuelve a obtener que el método menos eficaz desde el punto de vista de la media mcr es el método del histograma y que el que tiene más veces la menor tasa de error es el método de coocurrencia en color.

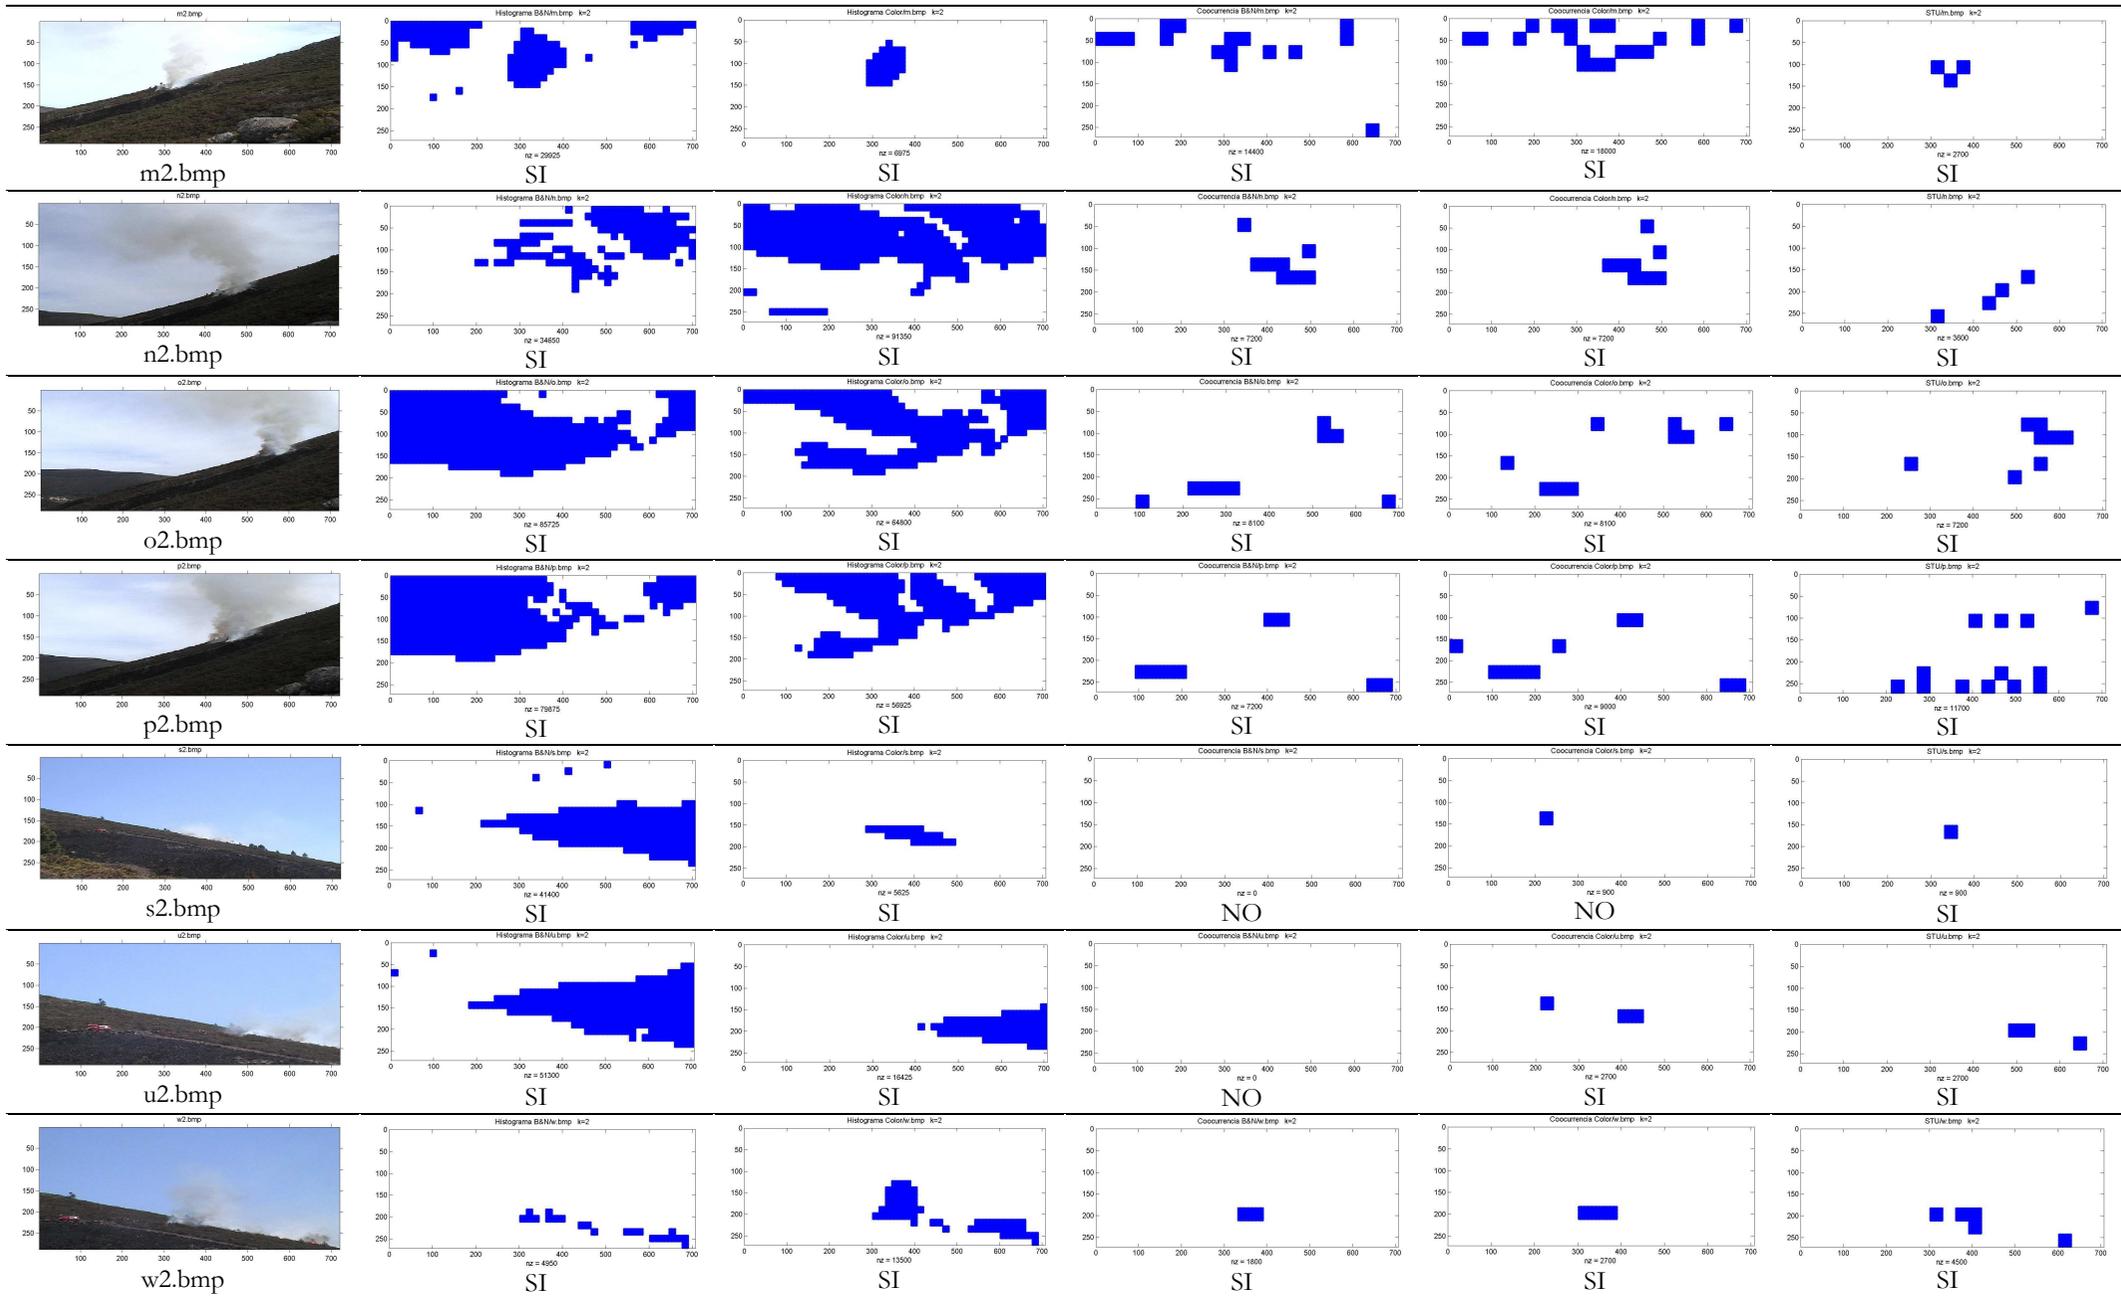
De la misma manera, a continuación se presenta una tabla con las imágenes segmentadas para cada método y se observa que el porcentaje de acierto en la detección toma valores muy distintos a los que antes se habían tomado:

Histograma en blanco y negro	→ 100% de acierto (13 de 13 imágenes)
Histograma en color	→ 100% de acierto (13 de 13 imágenes)
Coocurrencia en blanco y negro	→ 84.6% de acierto (11 de 13 imágenes)
Coocurrencia en color	→ 92.3% de acierto (12 de 13 imágenes)
STU	→ 92.3% de acierto (12 de 13 imágenes)

Se ha supuesto acierto en la segmentación si estaba incluido el humo aunque por error se hubiesen detectado más elementos.

Tabla 19. Pruebas de detección de humo de 13 imágenes teniendo como base de datos muestras de la imagen "w.bmp" ampliada con muestras de otras imágenes.

NOMBRE Porcentaje detección →	HISTOGRAMA B&N 13/13 → 100%	HISTOGRAMA COLOR 13/13 → 100%	COOCURENCIA B&N 11/13 → 84.6%	COOCURR. COLOR 12/13 → 92.3%	STU 12/13 → 92.3%
 a2.bmp	 SI nz = 11250	 SI nz = 7550	 SI nz = 2700	 SI nz = 900	 SI nz = 900
 b2.bmp	 SI nz = 11475	 SI nz = 6750	 SI nz = 5400	 SI nz = 3600	 SI nz = 2700
 d2.bmp	 SI nz = 20700	 SI nz = 16500	 SI nz = 35600	 SI nz = 24300	 SI nz = 18000
 e2.bmp	 SI nz = 43950	 SI nz = 78525	 SI nz = 4500	 SI nz = 3600	 NO nz = 9000
 j2.bmp	 SI nz = 24750	 SI nz = 17100	 SI nz = 10800	 SI nz = 4500	 SI nz = 3600
 l2.bmp	 SI nz = 21600	 SI nz = 11250	 SI nz = 33300	 SI nz = 25200	 SI nz = 6300



5. Conclusiones

5.1. Importancia de la buena elección de la base de datos de muestras

Una buena elección de la base de datos determina de manera decisiva los resultados de los métodos, ya que los métodos estudiados de por sí tienen una eficacia mayor o menor, pero se apoyan en una base existente en un espacio de muestras.

Cada método saca unos descriptores de las muestras que se le proponen como base de datos, pero debe estar bien elegida.

El número de muestras que se propongan para la base de datos es indefinida, cuantas más muestras haya más definidas estarán las fronteras entre una clase y otra. Asimismo, puede haber un número indeterminado de clases distintas. Ahora bien, las muestras de una misma clase deben definirla de manera coherente, es decir, que las muestras de la clase deben contener la información que caracteriza a esa clase.

En este trabajo se han formado dos clases distintas, la clase humo y la clase no-humo. Para ver de manera gráfica la influencia que tiene hacer una modificación en las muestras del espacio muestral se han unido las dos gráficas de resultados obtenidas en el apartado anterior donde se calcularon las tasas de error cruzado para la base de datos normal y la base de datos ampliada. Se debe recordar que la base de datos ampliada tan sólo contiene 4 muestras más para cada clase.

Observando la superposición de las gráficas de la figura 75 se puede deducir que 9 de las 13 imágenes han mejorado en media la tasa de error, mientras que 4 de las 13 dan mejores resultados con la base de datos normal. Por tanto la tendencia que se concluye de aquí es que el buen funcionamiento del clasificador va a depender sobremanera de que las bases de datos de las clases tengan suficiente información.

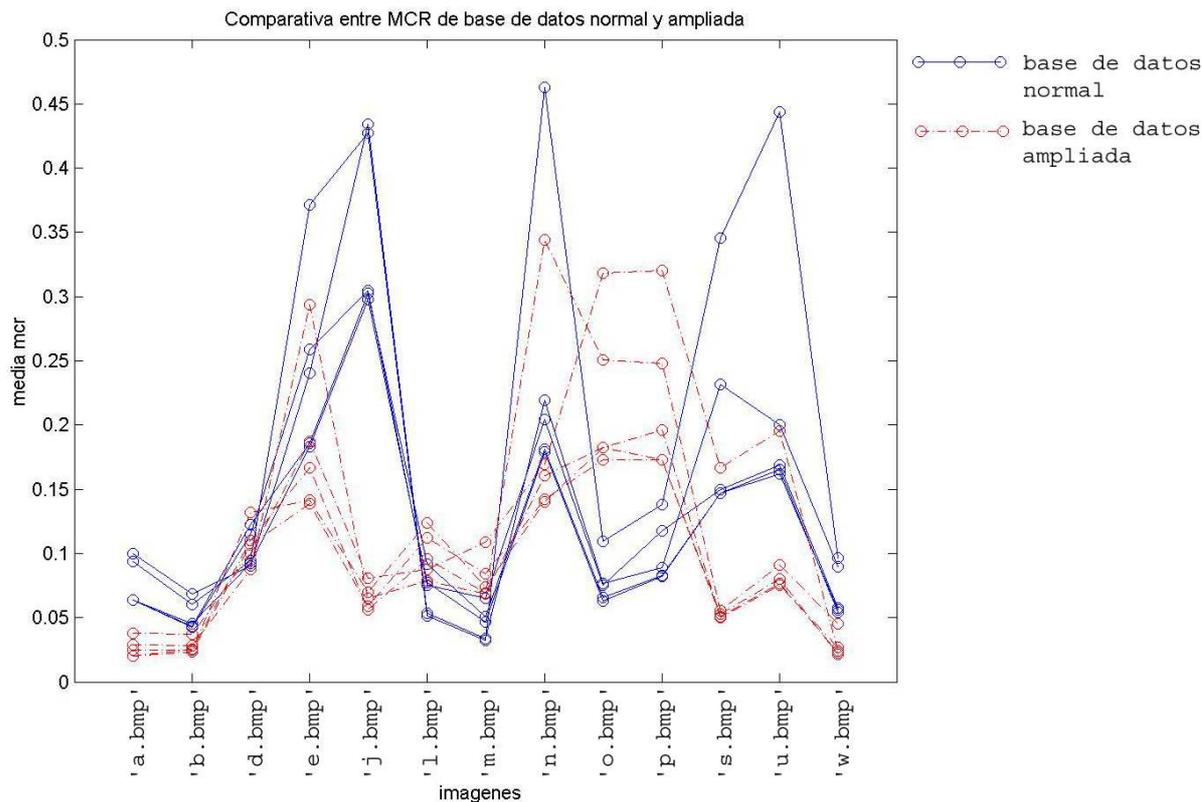


Figura 75. Comparativa entre la tasa de error MCR de la base de datos normal y de la base de datos ampliada

5.2. Eficacia de los distintos métodos

Atendiendo a la tasa de error cruzado el método más eficaz es el método basado en la matriz de coocurrencia con color. El método basado en la STU también ofrece resultados consistentes a la hora de segmentar el humo de una imagen.

En cambio, si se quisiese hacer una valoración de los métodos atendiendo al porcentaje de acierto se concluiría que el método del histograma en blanco y negro y en color son los más eficaces. Es decir, los métodos basados en la clasificación por textura a veces se combinan con otros métodos basados en el color, el movimiento, la temperatura, etc. Y por esto, en ocasiones interesa más que el método sólo segmente el humo, que en todas las ocasiones detecte el humo aunque detecte más elementos por error que confunda con el humo.

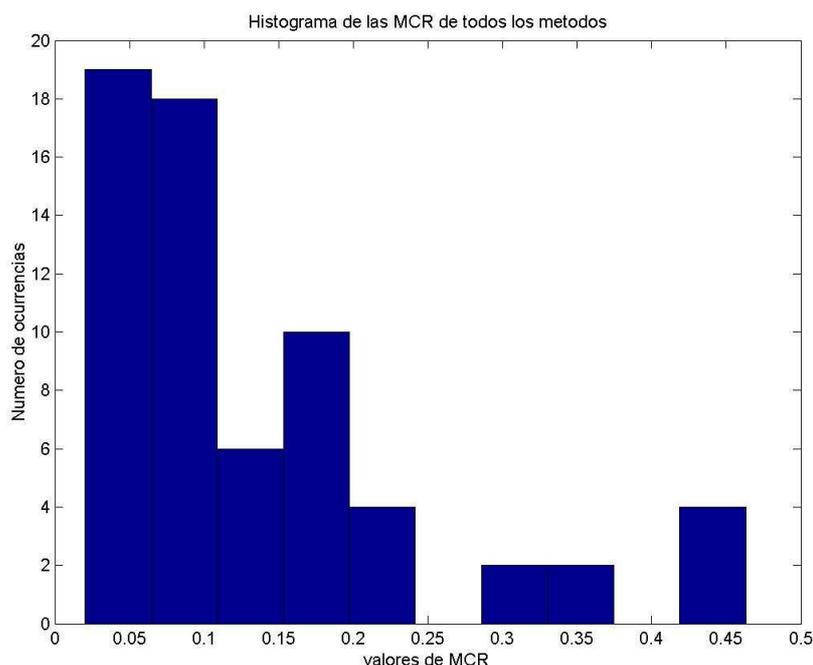


Figura 76. Estadística de la distribución de las tasas de error de las imágenes de pruebas para cada método.

Se puede observar en la figura 76 que los métodos utilizados ofrecen una tendencia a tener tasas de error cruzado pequeñas, salvo casos particulares en las que las tasas de error se disparan a valores elevados. Pero ocurre en un número pequeño de casos.

5.3. Mejoras

Algunas mejoras que se podrían realizar al proyecto serían las siguientes:

- Extender el número de clases, de manera que se pudiese distinguir en la clasificación entre distintos tipos de humo, ya que el humo puede presentarse con distintos aspectos según sea la naturaleza del objeto de donde proceda el humo. Los métodos utilizados detectan el humo pues sólo se han almacenado clases con información de qué es y qué no es humo. Si se crean clases de distintos tipos, ya sea vegetación, nubes, zonas rocosas o cualquier otra zona de interés con una textura determinada, ayudaría a la segmentación

del humo. Por otro lado, si una imagen es fija (i.e. una cámara fija) se puede usar algún método de intrusión de unas texturas en otras, etc.

- En este trabajo tan sólo se han probado tres métodos distintos, bien en color, bien en blanco y negro. Existen más métodos basados en la detección de texturas que se podrían utilizar para la segmentación de imágenes de humo.
- Aunque no se ha desarrollado en este documento, se han probado técnicas de ecualización local y global de imágenes sin haber obtenido éxito en los resultados. Se podría tratar de encontrar un método de ecualización de las imágenes que no perdiese información en los píxeles de textura, y mejorar el resultado de las segmentaciones.
- También se ha probado sin éxito una modificación del método STU (Simplified Texture Unit) con la idea de hacer capaz al método de usar la información del color en los resultados. El resultado fue insatisfactorio, por lo que no se añadió a los resultados finales. Se podría intentar modificar el método para realizar un STU/color, aunque no es imprescindible ya que si se desea hacer una segmentación utilizando también el color se puede realizar separadamente la segmentación por el método en cuestión y por descriptores de color y luego hacer una intersección de resultados en la segmentación.

6. Bibliografía

- Francisco J. Madrid-Cuevas, R. Medina Carnicer, M. Prieto Villegas, N. L. Fernández García, and A. Carmona Poyato. *Simplified Texture Unit: A New Descriptor of the Local Texture in Gray –Level Images*. Department of Computing and Numerical Analysis, Córdoba University, 2003.
- Dong-Chen He and Li Wang. *Texture Unit, Texture Spectrum, and Texture Analysis*. IEEE Transactions on Geoscience and Remote Sensing. Vol. 28, No. 4, July 1990.
- *Estudio Comparativo de medidas de Texturas Aplicado a Dermatología*. Universidad de Sevilla.
- M^a Ángeles Quintero Hernández. *Análisis de Texturas de Imágenes Mediante Representación de Wavelets Discretas*. Universidad de Sevilla, 1999.
- Noelia Cáceres Sánchez. *Algoritmo de Segmentación de Imágenes basado en Información de Color y Textura*. Universidad de Sevilla, 2004.
- Manuel Algar González. *An Investigation into Feature Selection and Machine Learning for Detecting Disease From Lung Scans*. University of Bristol, Department of Engineering Mathematics, 2004.
- Patricia Ruiz Belloso. *Segmentación de Imágenes basada en el Color y la Textura Empleando el Método del Crecimiento de Regiones y la Energía de Bordes Conseguida a Través de los Filtros de Gabor*. Universidad de Sevilla, 2004.
- *Ecuilización del Histograma*. http://sabia.tic.udc.es/gc/trabajos%202005-06/procesado%20digital%20de%20imagen/pagina_nueva_15.htm
- T. Ojala. A comparative study of texture measures with classification based on feature distributions. Technical report, University of Maryland, Center for Automatic Research., <ftp://ftp.cfar.umd.edu/Ts/CVL-Reports-1996/TR371-ojala.ps.gz>, 1996.
- Gustavo Drets, Rosario Curbelo, Olaf Bergengruen, Andrés Almansa. *Métodos de Impresión Fiel para Huellas Dactilares*. Universidad de la República Montevideo, Uruguay, 29 de Noviembre de 1995.

- Miriam Presutti. *La Matriz de Co-ocurrencia en la Clasificación Multiespectral: Tutorial para la Enseñanza de Medidas Texturales en Cursos de Grado Universitario*. Universidad Nacional de La Plata, agosto de 2004.
- *k-Nearest Neighbor Algorithm (KNN); Cross Validation Algorithm; Crossover Error Rate (CER); Misclassification Rate (MCR) and Equal Error Rate (EER)*. Keywords obtained from www.wikipedia.org