



Treball Fi de Carrera

Enginyeria Tècnica de Telecomunicació

Especialitat en Sistemes Electrònics

**Evaluación de la regeneración ósea mediante
procesado de imagen**

Aleix Pascual Merino

Director: José Manuel Álvarez López

Departament de Ciències de la Computació

Escola Tècnica Superior d'Enginyeria (ETSE)

Universitat Autònoma de Barcelona (UAB)

Juliol 2010



El tribunal d'avaluació d'aquest Treball Fi de Carrera, reunit el dia _____,
ha acordat concedir la següent qualificació:

--

President: _____

Vocal: _____

Secretari: _____



El sotasignant, José Manuel Álvarez López, Professor de l'Escola Tècnica Superior d'Enginyeria (ETSE) de la Universitat Autònoma de Barcelona (UAB),

CERTIFICA:

Que el treball presentat en aquesta memòria de Treball Fi de Carrera ha estat realitzat sota la seva direcció per l'alumne Aleix Pascual Merino.

I, perquè consti a tots els efectes, signa el present certificat.

Bellaterra, 26 de Maig de 2010.

Signatura: José Manuel Álvarez López

A mis padres y especialmente a mi abuela.

Índice

1. Introducción.....	1
2. Descripción del método.....	3
2.1. Extracción de las características de las imágenes.	3
2.2. Diseño del algoritmo de clasificación.	11
3. Experimentos.....	15
3.1. Adquisición de las imágenes.....	15
3.2. Primer parámetro de estudio: momentos del histograma.....	16

3.3. Segundo parámetro de estudio: tamaño histogramas.....	18
3.4. Tercer parámetro de estudio: tamaño máscara.....	19
3.5. Cuarto parámetro de estudio: modas	22
3.6. Quinto parámetro de estudio: distribución de los píxeles	26
3.6.1. Primer criterio	26
3.6.2. Segundo criterio	28
3.7. Clasificador de distancia euclídea.....	29
3.7.1. Set-up del clasificador de distancia euclídea.	30
3.7.2. Análisis de imágenes	31
3.8. Clasificador Bayesiano	31
3.8.1. Análisis de imágenes	33
3.9. Comparación de los clasificadores.....	34
4. Conclusiones	37
5. Bibliografía.....	39

1. Introducción

La osteogénesis es el proceso de formación o desarrollo de los huesos, el cual es estudiado por expertos de todo el mundo. Estos expertos necesitan encontrar materiales capaces de acelerar el proceso de formación de tejido óseo en zonas donde se han producido defectos óseos. Actualmente se estudian diversos materiales inorgánicos similares a la matriz ósea (plasma rico en plaquetas, extracto de médula ósea rico en plaquetas, β -fosfato tricálcico) que se aplican sobre defectos óseos que se han producido de manera natural o no, para después valorar la capacidad de regeneración ósea que nos proporciona cada material.




Fig. 1 Estudio de materiales que ayudan a la regeneración de tejido óseo.

Después de un determinado periodo de tiempo de aplicación de los materiales de estudio en la zona que carecía de tejido óseo, se obtienen imágenes de dicha zona a través de microscopios, rayos-X, o resonancia magnética:

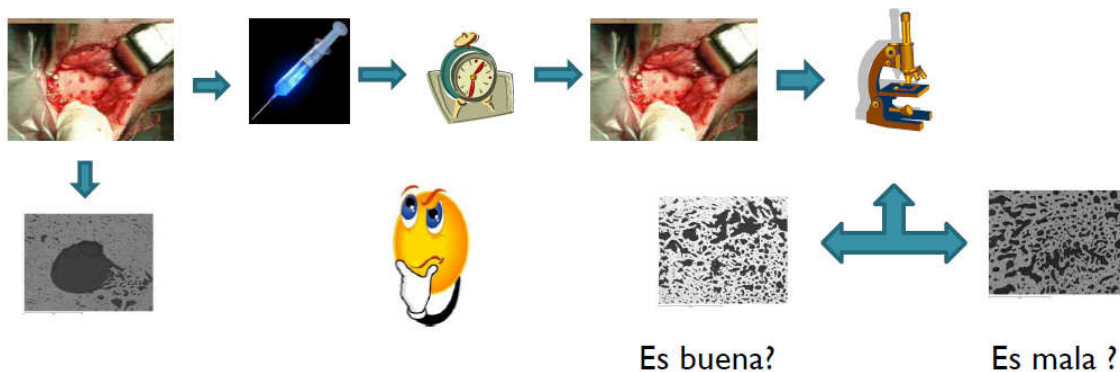


Fig. 2 Obtención de las imágenes.

El experto mediante la inspección visual de esas imágenes evalúa si el hueso se ha regenerado bien o no y en consecuencia se determina qué material de estudio nos proporciona una mayor capacidad de regeneración ósea.

El problema de la actual evaluación del análisis de la capacidad de regeneración ósea es que requiere un experto y que la valoración de éste es subjetiva y difícil de cuantificar, lo que puede provocar que exista cierta discordancia entre dos expertos. Además, es posible que tras analizar muchas veces la misma imagen el experto en algún momento cambie su diagnóstico respecto a esa imagen.



Fig. 3 Evaluación de la regeneración ósea realizada por expertos.

Con el fin de aprovechar las imágenes en las que se basa el experto para evaluar la capacidad de regeneración ósea se propone realizar un análisis cuantitativo de la regeneración ósea basado en el procesamiento de imagen mediante el programa Matlab. El algoritmo diseñado es capaz de clasificar imágenes de la mandíbula en: imágenes de regeneración buena e imágenes de regeneración mala a través de parametrizar el histograma de niveles de gris de la imagen. Por tanto, el algoritmo nos permitirá cuantificar qué material nos proporciona una mejor regeneración ósea. El clasificador diseñado solventa la falta de objetividad y la necesidad de un experto para valorar la capacidad de regeneración ósea.

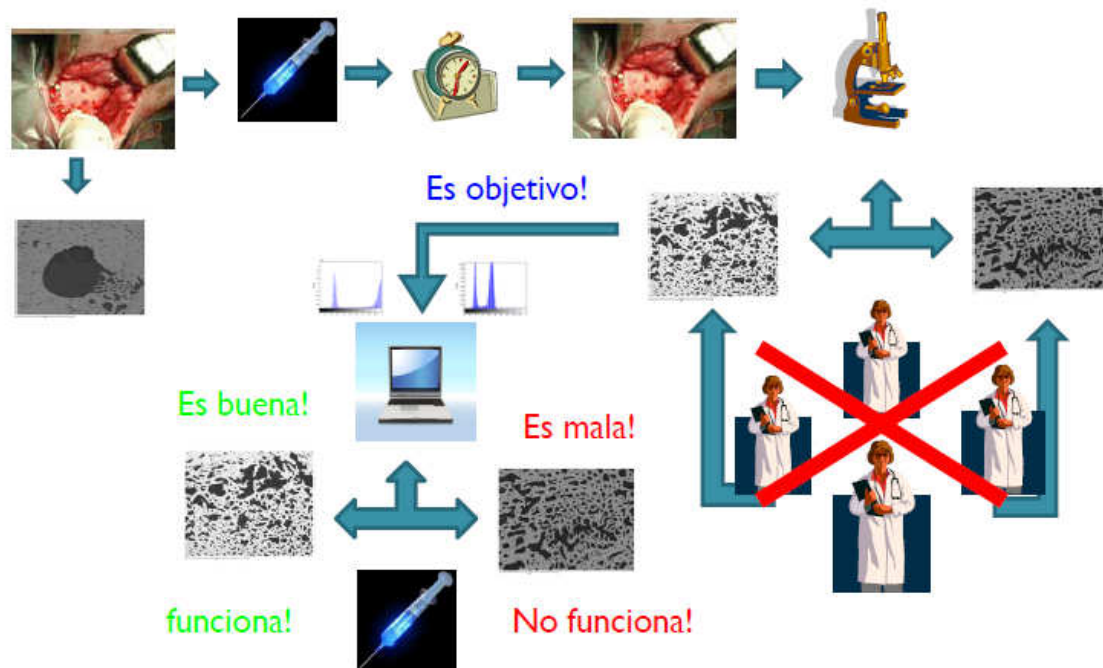


Fig. 4 Diseño del algoritmo para el análisis cuantitativo de la regeneración ósea basado en el procesamiento de imagen.

Encontramos artículos en la literatura como [3] [4] y [5] sobre el análisis de la regeneración ósea mediante el procesamiento de imagen. En dichos artículos se analizan imágenes de rayos-X y resonancia magnética para realizar un seguimiento de la regeneración ósea, pero sin llegar a evaluar si la regeneración ósea es buena o no.

2. Descripción del método

Previamente, el médico especialista nos ha informado del grado de regeneración de cada una de las imágenes de la mandíbula que se analizarán, es decir, si una imagen corresponde a una regeneración buena o mala. La Fig. 5 nos muestra dos ejemplos de las imágenes que vamos a utilizar:




Fig. 5 Ejemplos de imágenes: (izquierda) regeneración buena, (derecha) regeneración mala.

Como las imágenes son de médula ósea, no nos importa cómo está distribuida la imagen de manera espacial, ni tampoco propiamente el color de la imagen, sino en cómo se distribuyen los píxeles a través de una escala de grises, o lo que es lo mismo, la distribución de intensidades, por eso la mejor manera de caracterizar las imágenes de médula ósea será a través del histograma de niveles de gris.

2.1. Extracción de las características de las imágenes.

En procesamiento de imagen se acostumbra a dividir una imagen en diferentes regiones para su análisis, el siguiente paso es representar esas distintas regiones según sus características. Para representar las distintas regiones existen dos posibles opciones:

1. Podemos representar la región en términos de sus características externas a la misma región.
2. Podemos representar la región en función de sus características internas estudiando los píxeles que están dentro de esa región.

La representación interna se utiliza para observar las propiedades de la región seleccionada, como el color y la textura. Estas propiedades son las que nos interesan para determinar el grado de regeneración ósea donde la región a analizar vendrá determinada por una máscara circular que delimita dicha región.

Existen varios métodos para caracterizar una imagen según la forma, analizando sus extremos, según la distancia desde el centro de la imagen hasta los bordes, pero en nuestro caso la información para caracterizar la imagen no está en la forma o en cómo se distribuyen los píxeles de forma espacial en la imagen.

También existen métodos para describir la frontera de una región, donde la forma de la frontera se puede describir mediante momentos estadísticos como la media, la varianza y otros momentos de orden mayor, pero en nuestro caso nos interesa lo que hay dentro de la región que queremos analizar.

A la hora de analizar las regiones de interés, un parámetro importante será el número de píxeles que contiene el área o región que vamos a analizar, por tanto será un parámetro más a tener en cuenta. Otras medidas que se utilizan para describir regiones son la media de nivel de gris, el mínimo y el máximo nivel de gris y el número de píxeles por debajo y por encima de la media.

Un método muy importante para describir una región es cuantificar su textura. No hay ninguna definición formal de textura, pero intuitivamente proporciona medidas como la suavidad o regularidad. El análisis de la textura se refiere a las técnicas algorítmicas desarrolladas para cuantificar las propiedades de textura de una imagen.

Los tres principales enfoques utilizados en el procesamiento de imagen para describir la textura de una región son estadísticos, estructurales y espectrales. Los enfoques estadísticos pueden caracterizar texturas como suave, áspero, y regular. La Fig. 6 muestra unos ejemplos:




Fig. 6 De izquierda a derecha respectivamente, suave (*smooth*), áspero (*coarse*), regular. Son imágenes realizadas con un microscopio óptico de respectivamente: un superconductor, colesterol humano, y un microprocesador. Imagen obtenida de [1].

Uno de los enfoques más sencillos para describir la textura de una imagen es utilizar los momentos estadísticos del histograma de niveles de gris de la imagen o una región de dicha imagen. Los diferentes momentos nos sirven para parametrizar el histograma. Definimos z como los posibles valores de nivel de gris que puede tomar un píxel de manera aleatoria y $p(z)$ el histograma correspondiente, donde L es el número de distintos niveles de gris.

La siguiente ecuación muestra el n -ésimo momento:

$$\mu_n = \sum_{i=0}^{L-1} (Z_i - m)^n \cdot p(z_i)$$

Donde la media del nivel de gris es:

$$m = \sum_{i=0}^{L-1} z_i \cdot p(z_i)$$

La media nos dice como es de intensa una imagen. Las imágenes de regeneración buena poseen una mayor intensidad que las imágenes de regeneración mala, pues un gris claro es más intenso que un gris oscuro.

El primer momento es la desviación estándar:

$$\mu_1 = \sum_{i=0}^{L-1} (Z_i - m)^1 \cdot p(z_i) \quad \sigma = \sqrt{\mu_2(z)} = \sqrt{\sigma^2}$$

La desviación estándar es usada como una medida frecuente de textura, nos da una media de contraste. Las imágenes de regeneración buena tienen un mayor contraste, pues en una determinada región los píxeles pasarán de tener un nivel de gris oscuro a blanco. Los valores de desviación estándar tienden a ser más intuitivos para mucha gente que los valores de varianza, el segundo momento:

$$\mu_2 = \sum_{i=0}^{L-1} (Z_i - m)^2 \cdot p(z_i)$$

La varianza también es utilizada como medida del contraste para describir imágenes de relativa tranquilidad (*smoothness*). Una medida relacionada con la varianza es la medida R que se define como:

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

Su valor es 0 para regiones de intensidad constante (donde la varianza es cero) y toma el valor 1 cuando la varianza toma valores grandes. La varianza tiende a tomar valores grandes para imágenes con escala de grises en el rango de 0 a 255, por tanto es una buena idea normalizar la varianza en el intervalo [0,1] y así poder aplicar la varianza en la ecuación anterior. Para normalizar la varianza simplemente tenemos que aplicar la siguiente ecuación:

$$\frac{\sigma^2}{(L-1)^2}$$

La medida R nos proporciona la misma información que la varianza o desviación estándar.

El tercer momento es la asimetría (*skewness*), la cual es útil para determinar el grado de simetría de los histogramas porque ésta nos da una idea de si los píxeles están más concentrados hacia niveles de gris claros (histograma sesgado a la izquierda, sesgo negativo) o niveles de gris oscuros (histograma sesgado a la derecha, sesgo positivo) respecto la media.

$$\mu_3 = \sum_{i=0}^{L-1} (Z_i - m)^3 \cdot p(z_i)$$

Existen algunas medidas adicionales que nos hablan de la textura las cuales nos pueden ser muy útiles, como lo puede ser la medida de uniformidad:

$$U = \sum_{i=0}^{L-1} p^2(z_i)$$

U toma el valor máximo para una imagen en que los niveles de grises sean iguales (máxima uniformidad).

Otra medida que nos habla de la textura de una imagen es la entropía:

$$e = - \sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i)$$

La entropía se entiende como una medida de variabilidad donde toma el valor 0 para una imagen constante. Nos da la misma información que la uniformidad, donde la entropía será máxima para una imagen que sea poco uniforme.

La Tabla 1 muestra los resultados obtenidos después de analizar las imágenes, de la Fig. 6.

Texture	Mean	Standard deviation	R (normalized)	Third moment	Uniformity	Entropy
Smooth	82.64	11.79	0.002	-0.105	0.026	5.434
Coarse	143.56	74.63	0.079	-0.151	0.005	7.783
Regular	99.72	33.73	0.017	0.750	0.013	6.674

Tabla 1 Momentos estadístico obtenidos de las imágenes de la Fig. 6. Tabla obtenida de [1].

Si observamos la Tabla 1 vemos que la media nos dice cómo es de intensa la imagen. Para una imagen suave la desviación estándar es claramente más pequeña que para una imagen rugosa o regular, y lo mismo nos indica R (normalized) que esencialmente significa lo mismo que la desviación estándar. El tercer momento nos da una idea de si los píxeles están concentrados hacia niveles de grises claros (histograma sesgado a la izquierda, sesgo negativo) u oscuros (histograma sesgado a la derecha, sesgo positivo) respecto la media. Mirando la medida de uniformidad, observamos que la primera imagen es más suave (más uniforme que el resto) y la de más rango (menos uniformidad) corresponde a la imagen más áspera. Finalmente, los valores de la entropía nos llevan a las mismas conclusiones que la medida de la uniformidad, es decir, la imagen más suave tiene menos entropía, lo cual es lógico, pues tiene menos incertidumbre.

Las medidas de textura calculadas utilizando sólo histogramas sufren limitaciones, pues no contienen información sobre la posición relativa de píxeles con respecto a los otros, pero en nuestro caso no es una limitación pues no nos importa la posición que ocupan los píxeles en la imagen.

Veamos como son los histogramas de las imágenes de la Fig. 5:




Fig. 7 A la izquierda tenemos el histograma de la imagen de regeneración buena y a la derecha el histograma de la imagen de regeneración mala. Ambos histogramas son de 256 niveles de gris.

Si observamos la Fig. 7 vemos que ambos histogramas poseen dos modas. La moda que está a la derecha nos da información sobre el nivel de gris que posee el tejido óseo en la imagen, pues está más cerca de los niveles claros de gris. Por otro lado, la moda que está a la izquierda nos dice el nivel de gris que posee la ausencia de tejido óseo, pues está más cerca de los niveles oscuros de gris.

Es útil definir un umbral entre las dos modas para poder dividir el histograma en dos zonas: los píxeles que corresponden a la presencia de tejido óseo y los píxeles que corresponden a la ausencia de tejido óseo. Para ello debemos estimar el umbral que produce el mínimo error de segmentación. Hemos definido z como los posibles valores de nivel de gris que puede tomar un píxel. Podemos considerar los posibles niveles de gris como variables aleatorias, en consecuencia podemos considerar su histograma como la *PDF (Probability density Function)* de $p(z)$.

Esta *PDF* resultante o total, es la suma o mezcla de dos densidades: una correspondiente a la región oscura de la imagen, ausencia de tejido óseo y otra a la región clara de la imagen, presencia de tejido óseo. Si suponemos o conocemos las dos densidades, se puede determinar un umbral óptimo (en términos de error mínimo), para segmentar la imagen en dos regiones distintas.

La Fig. 8 muestra dos funciones de densidad de probabilidad. Suponemos que $p_2(z)$ corresponde a niveles de gris claros, presencia de tejido óseo y $p_1(z)$ corresponde a niveles de gris oscuro que corresponden a una ausencia de tejido óseo.




Fig. 8 PDF de $p_1(z)$ y $p_2(z)$ y sus respectivas medias. Imagen obtenida de [1].

La mezcla de densidades de probabilidad que describe la función densidad de probabilidad para todos los niveles de grises se puede escribir como:

$$p(z) = P_1 p_1(z) + P_2 p_2(z)$$

Donde P_1 es la probabilidad de que un píxel tome un valor z , correspondiente a un nivel de gris de ausencia de tejido óseo, y P_2 es la probabilidad de que un píxel tome un valor z , correspondiente a un nivel de gris de presencia de tejido óseo. Entonces asumimos que para cualquier píxel dado, pertenecerá a la presencia de tejido óseo o a la ausencia de tejido óseo:

$$P_1 + P_2 = 1$$

Por lo tanto, los píxeles que tengan un nivel de gris superior a T pertenecerán a la presencia de tejido óseo, y el resto a la ausencia de tejido óseo. Nuestro principal objetivo es seleccionar el valor de T que minimice el error a la hora de decidir si un píxel pertenece a la presencia de tejido óseo o no.

Recordamos que la probabilidad de que una variable aleatoria tome el valor en el intervalo $[a,b]$ es la integral de su función densidad de probabilidad cuyos límites de integración son a y b , que corresponde al área de la PDF entre esos límites. Entonces, la probabilidad de error de clasificar un píxel que corresponde a la presencia de tejido óseo como un píxel que pertenece a la ausencia de tejido óseo:

$$E_1(T) = \int_{-\infty}^T p_2(z) dz$$

Cuya área pertenece a $p_2(z)$ en la parte izquierda del umbral de decisión. Del mismo modo, la probabilidad de error de clasificar un píxel que corresponde a la ausencia de tejido óseo como la presencia de tejido óseo es:

$$E_2(T) = \int_T^{\infty} p_1(z) dz$$

Cuya área pertenece a $p_1(z)$ en la parte derecha del umbral de decisión. Entonces podemos decir que la probabilidad de error es:

$$E(T) = P_2 E_1(T) + P_1 E_2(T)$$

El umbral optimo es donde las curvas $p_1(z)$ y $p_2(z)$ se cruzan.

Para obtener la expresión analítica para encontrar T , requiere conocer la ecuación de ambas PDF. La estimación de estas densidades a la práctica no es siempre factible, y normalmente se emplean densidades cuyos parámetros son razonablemente sencillos de obtener. Una de las principales densidades que se utiliza es la gaussiana, que está totalmente caracterizada por dos parámetros: la media y la varianza. En este caso:

$$p(z) = \frac{P_1}{\sqrt{2\pi}\sigma_1} e^{-\frac{(z-\mu_1)^2}{2\sigma_1^2}} + \frac{P_2}{\sqrt{2\pi}\sigma_2} e^{-\frac{(z-\mu_2)^2}{2\sigma_2^2}}$$

Donde μ_1 y σ_1^2 son la media y la varianza de la gaussiana correspondiente a los píxeles que toman un valor de gris que pertenece a la ausencia de tejido óseo y μ_2 y σ_2^2 son la media y la varianza de la gaussiana correspondiente a los píxeles que toman un valor de gris que pertenecen a la presencia de tejido óseo.

Si suponemos que las varianzas son iguales $\sigma=\sigma_1=\sigma_2$ un solo umbral es suficiente:

$$T = \frac{\mu_1 + \mu_2}{2} + \frac{\sigma^2}{\mu_1 - \mu_2} \ln\left(\frac{P_2}{P_1}\right)$$

Si $P_1=P_2$, entonces el umbral óptimo será:

$$T = \frac{\mu_1 + \mu_2}{2}$$

Lo mismo es cierto si $\sigma=0$.

En nuestro caso se supondrá que ambas varianzas son iguales y que la probabilidad de que un píxel tome un valor de gris que pertenece a tejido óseo y la probabilidad de que pertenezca a una ausencia de tejido óseo es la misma.

También supondremos que la posición de las modas corresponden al valor de μ_1 y μ_2 , entonces podremos obtener de forma sencilla el umbral óptimo y cuantificar los píxeles que hay a banda y banda del umbral, para conocer los píxeles que corresponden a la presencia de tejido óseo y los píxeles que corresponden a la ausencia de tejido óseo.

Otro umbral que se utilizará para el sistema de clasificación de imágenes es justo la mitad del histograma, de manera que a la izquierda del umbral tenemos el número de píxeles que toman un nivel oscuro de gris, ausencia de tejido óseo, y a la derecha del umbral el número de píxeles que toman un nivel claro de gris, presencia de tejido óseo.

2.2. Diseño del algoritmo de clasificación.

Para el diseño del algoritmo de clasificación se ha partido del conocido clasificador Bayesiano. El clasificador Bayesiano consiste en restar los píxeles de un determinado nivel de gris de un histograma respecto a los píxeles del mismo nivel de gris de otro histograma. La suma total de la diferencia de píxeles para todos los niveles de gris es la distancia entre los dos histogramas. Creemos que el clasificador de Bayes nos puede fallar en el cálculo de distancias entre histogramas para determinar el grado de regeneración ósea de una imagen. A continuación analizaremos dos imágenes para que se entienda mejor el porqué nos puede fallar:




Fig. 9 Ambas imágenes son de regeneración ósea mala.

Obtenemos el histograma:

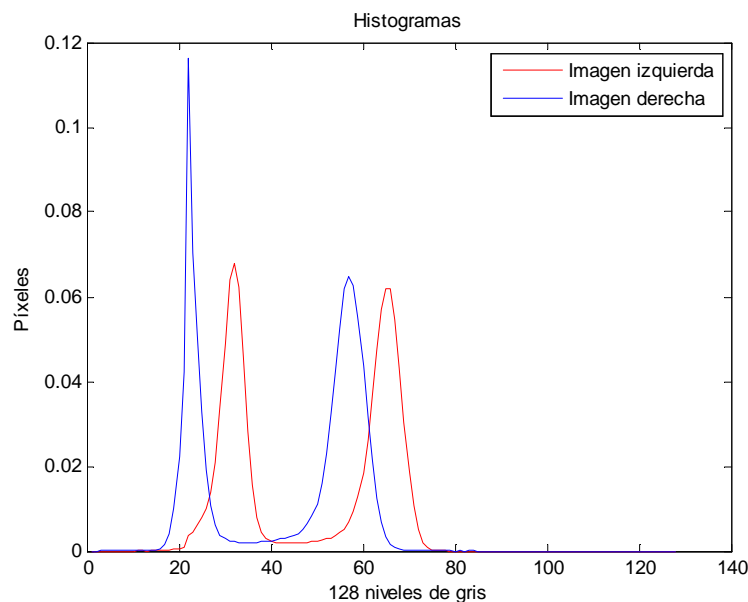


Fig. 10 Histogramas de 128 niveles de gris normalizados respecto al número de píxeles, de las imágenes de la Fig. 9.

Como podemos observar en la Fig. 10 ambas imágenes son de regeneración mala pero, sin embargo, si calculamos la distancia entre los histogramas mediante el clasificador de Bayes obtendremos que la distancia entre los histogramas es grande. Una pequeña

variación de la posición en las modas, es decir, una pequeña variación de las modas en la escala de grises nos distancia mucho los dos histogramas que pertenecen a imágenes de la misma clase, en este caso ambas imágenes son de regeneración mala.

El algoritmo de clasificación diseñado no se basa en calcular la distancia entre histogramas sino en calcular la distancia euclídea entre los parámetros que nos permiten parametrizar el histograma, donde cada parámetro es considerado una dimensión. Para ello se han analizado 20 imágenes diferentes y se han agrupado en: imágenes de regeneración buena y de regeneración mala. Después para cada clase de regeneración ósea se ha calculado la media de todos los parámetros que hemos obtenido de cada imagen para obtener dos modelos: un modelo de regeneración buena y otro modelo de regeneración mala.

Los parámetros de la imagen y de los modelos han sido normalizados, para que cada parámetro tenga el mismo peso a la hora de calcular la distancia euclídea entre la imagen y los dos modelos.

La Fig. 11 describe el funcionamiento del algoritmo de clasificación de distancia euclídea:

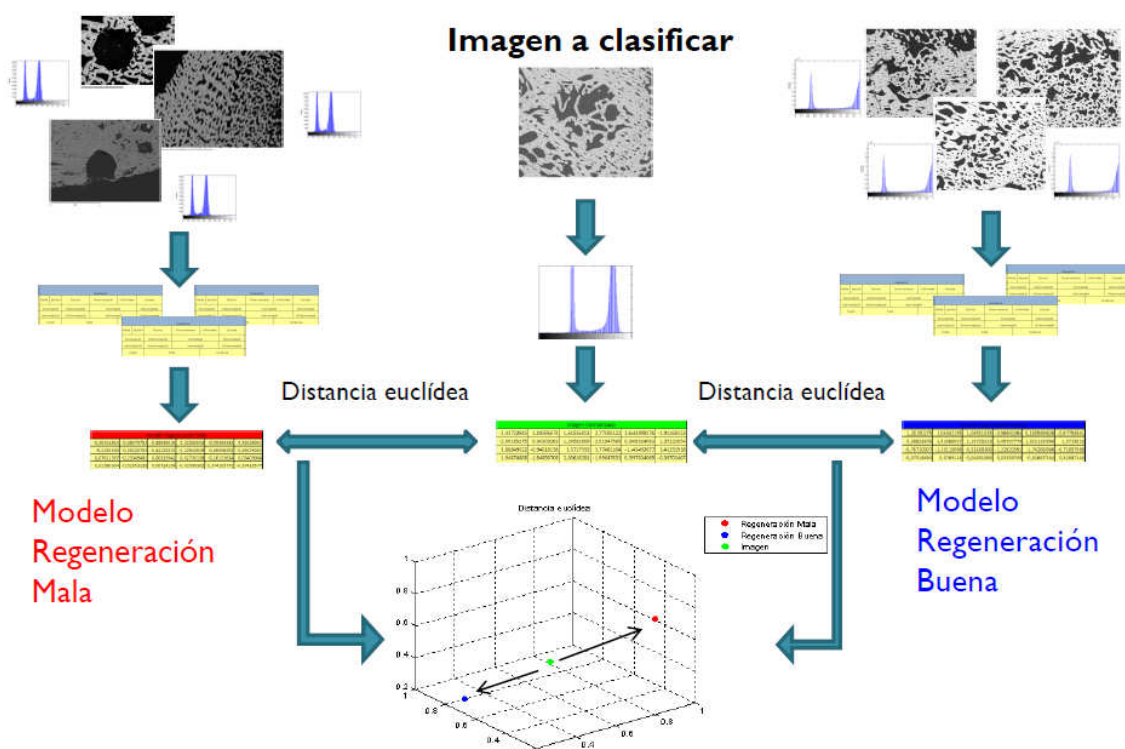


Fig. 11 Clasificador de distancia euclídea, en la parte inferior de la imagen se muestra un ejemplo en donde hay 3 puntos en un espacio de 3 dimensiones donde el punto verde corresponde a la imagen que se está analizando y los otros dos puntos a los dos modelos, las flechas simulan la distancia euclídea de la imagen respecto a los dos modelos en un espacio de 3 dimensiones.

La distancia euclídea entre dos puntos P y Q en un espacio euclídeo de n -dimensional se define como:

$$d(P, Q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}$$

En nuestro caso nos encontramos en un espacio de 24 dimensiones. Si la distancia euclídea es mínima de la imagen respecto al modelo de regeneración buena, significa que la imagen es de regeneración buena y si la distancia es mínima respecto al modelo de regeneración mala significa que la imagen es de regeneración mala.

La Tabla 2 muestra los 24 parámetros que nos permiten parametrizar el histograma, donde cada parámetro es considerado una dimensión:

Parámetros					
Media	DesvStd	R(norm)	Tercer momento	Uniformidad	Entropía
Posmodas128		Difposmodas128	Posmodas64		Difposmodas64
Valormodas128		Difvalormodas128	Valormodas64		Difvalormodas64
Pix128		Pix64		Tendencia	

Tabla 2. Parámetros que nos permiten parametrizar el histograma de cada imagen.

La primera fila corresponde a los momentos del histograma que se han comentado en el apartado 2.1 y también en la Tabla 1. El resto de parámetros se van a describir a continuación donde 128 se refiere a un histograma de 128 niveles de gris y 64 a un histograma de 64 niveles de gris.

Posmodas128:

- *Posmodas128(1)*: posición moda izquierda.
- *Posmodas128(2)*: posición moda derecha.
- *Difposmodas128*: posición moda derecha – posición moda izquierda.

Valormodas128:

- *Valormodas128(1)*: valor moda izquierda en píxeles.
- *Valormodas128(2)*: valor moda derecha en píxeles.
- *Difvalormodas128*: valor moda derecha – valor moda izquierda.

Pix128:

- *Pix128(1)*: número de píxeles en la zona izquierda del umbral en %.
- *Pix128(2)*: número de píxeles en la zona derecha del umbral en %.

Tendencia: en este caso el umbral está justo en la mitad del histograma.

- *Tendencia(1)*: número de píxeles en la zona izquierda del umbral en %.
- *Tendencia(2)*: número de píxeles en la zona derecha del umbral en %.

Las siguientes figuras muestran el resultado de aplicar el clasificador diseñado a las imágenes de la Fig. 5:

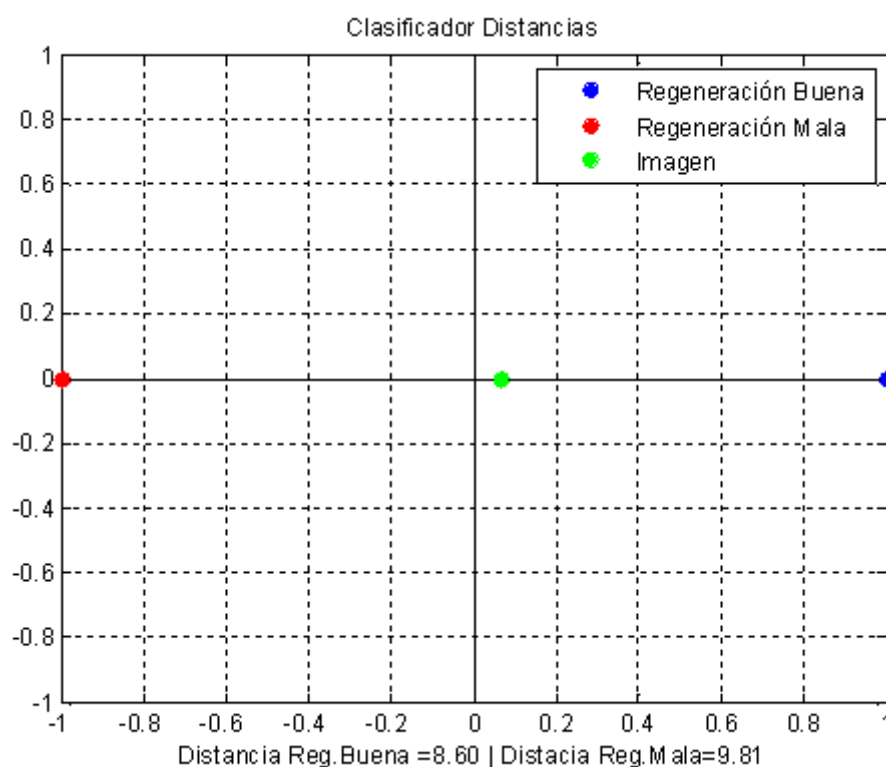


Fig. 12 Resultado de aplicar el clasificador de distancia euclídea a la imagen de regeneración buena de la Fig. 5.

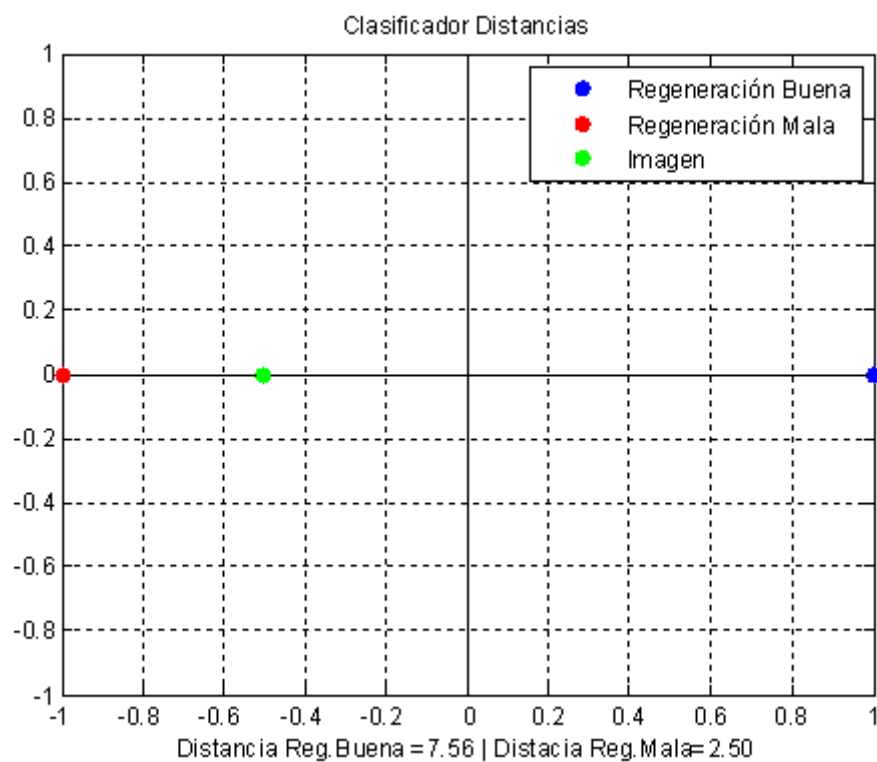


Fig. 13 Resultado de aplicar el clasificador de distancia euclídea a la imagen de regeneración mala de la Fig. 5.

3. Experimentos

En esta sección se mostrará de donde provienen las imágenes así como el proceso de análisis que se ha realizado para la extracción de los parámetros que nos permiten parametrizar el histograma de niveles de gris de cada imagen. Al final de este apartado se compararán el clasificador de distancia euclídea con el clasificador Bayesiano.

3.1. Adquisición de las imágenes

Las imágenes nos han sido proporcionadas por unos médicos de la Universidad de Barcelona que han realizado un estudio de la regeneración ósea en 10 mandíbulas, pertenecientes a ocho cerdos machos de 3 meses de edad los cuales fueron sometidos a una cirugía experimental. Las intervenciones quirúrgicas se realizaron en tres días de quirófano y bajo anestesia general donde les practicaron diez perforaciones de 8mm de profundidad mediante una fresa de 3,8mm de diámetro.

Las diferentes perforaciones realizadas se rellenaron con los diferentes materiales de estudio, excepto dos, que se dejaron sin relleno y que fueron consideradas como perforaciones de control.

Los diferentes materiales de estudio empleados fueron: 1) Control (C), ningún material. 2) Plasma pobre en plaquetas (PPP), 3) Plasma rico en plaquetas (PRP), 4) Médula ósea (M), procedente del propio animal. 5) β -Fosfato tricálcico (FT).

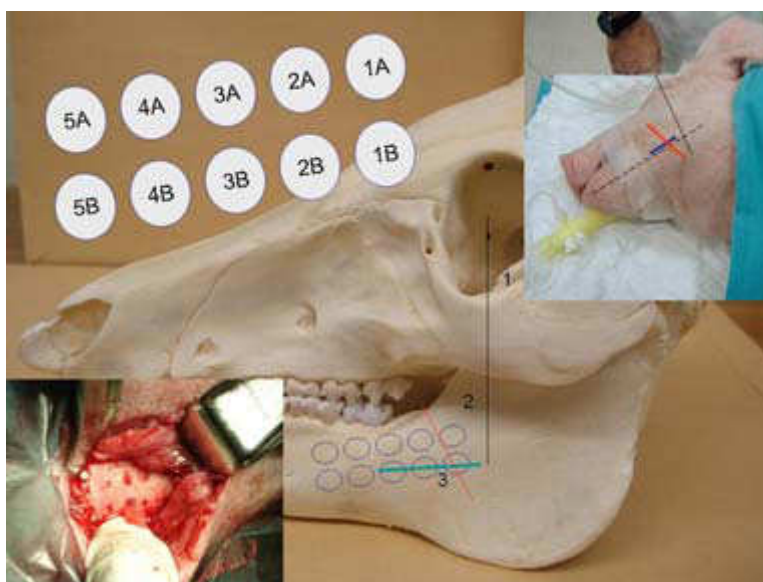


Fig. 14 Imagen mostrando la distribución de las perforaciones realizadas en las mandíbulas. En la imagen superior derecha e inferior izquierda se presenta la simulación y la cirugía correspondiente al animal número 4.

Después de la cirugía, los cerdos se mantuvieron en el Campus Universitario de Bellvitge durante dos meses, realizándose los controles y cuidados postoperatorios correspondientes. A los dos meses fueron sacrificados, para obtener las muestras que

fueron evaluadas. Las muestras fueron obtenidas mediante un microscopio electrónico de barrido. El microscopio electrónico de barrido utiliza un haz de electrones en lugar de un haz de luz para formar una imagen y en lugar de lentes utiliza electroimanes. Permite obtener imágenes de gran resolución en materiales pétreos, metálicos y orgánicos.

Las imágenes se obtienen mediante el software del propio microscopio el cual nos proporciona imágenes de 1.024x1.024 píxeles con una zona central útil de 1004x753 píxeles donde cada píxel se codifica en una escala de 256 posibles niveles de gris en el rango [0,1].

3.2. Primer parámetro de estudio: momentos del histograma

En este apartado se estudiarán los diferentes momentos que nos definen la textura de una imagen los cuales ya se vieron en el apartado 2.1 y nos permiten parametrizar el histograma de niveles de gris de la región de interés que queremos analizar.

Los diferentes momentos han sido obtenidos a través de aplicar una máscara de radio circular de 350 píxeles, donde el centro de la máscara corresponde al centro de la imagen, y sólo se analiza la región de la imagen que está dentro de la máscara, es decir, ésta delimitará la región de la imagen que queremos estudiar.

Veamos algunos ejemplos:

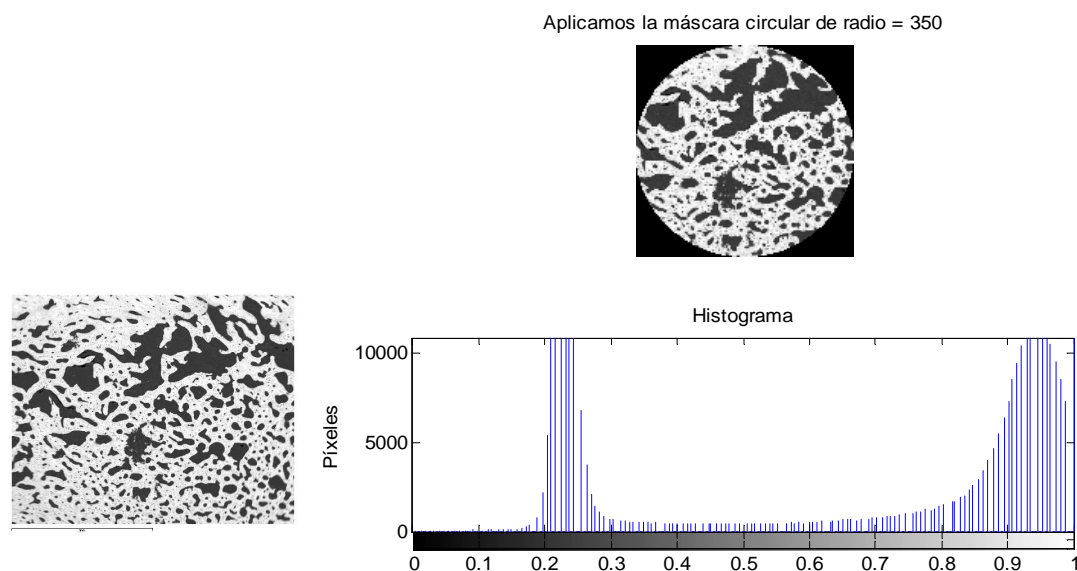


Fig. 15 A la izquierda ejemplo de regeneración buena, a la derecha arriba muestra la región que limita la máscara circular, y debajo el histograma de la región que limita la máscara.

<i>Media</i>	<i>DesvStd</i>	<i>R (norm)</i>	<i>Tercer momento</i>	<i>Uniformidad</i>	<i>Entropía</i>
160,96	85,63	0,1013	-2,5634	0,0326	5,5883

Tabla 3 Momentos correspondientes a la Fig. 15.

Aplicamos la máscara circular de radio = 350

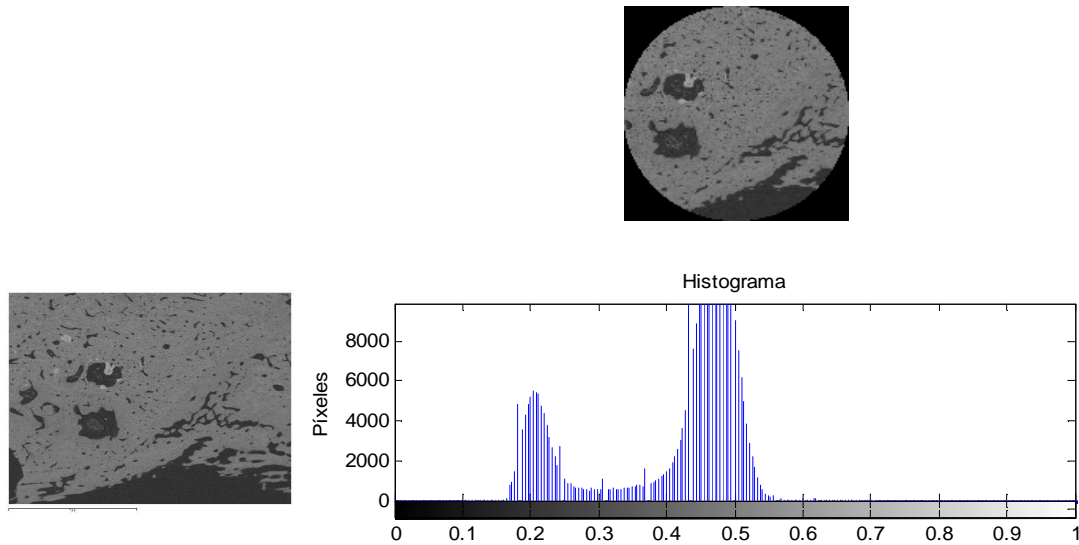


Fig. 16 A la izquierda ejemplo de regeneración mala, a la derecha arriba muestra la región que limita la máscara circular, y debajo el histograma de la región que limita la máscara.

Media	DesvStd	R (norm)	Tercer momento	Uniformidad	Entropía
83,72	33,28	0,0167	-0,1598	0,0297	5,6008

Tabla 4. Momentos correspondientes a la Fig. 16.

Observaciones:

- **Media:** claramente toma valores más altos para imágenes que corresponden a una buena regeneración ósea.
- **Desviación estándar:** también toma valores más altos para imágenes que corresponden a una buena regeneración ósea.
- **R(norm):** toma un valor mayor para imágenes que corresponden a una regeneración buena, pues nos proporciona la misma información que la desviación estándar.
- **Tercer momento:** tanto para imágenes de regeneración buena como de regeneración mala toma valores negativos. Aunque toma valores más negativos para imágenes de regeneración buena donde los píxeles están más concentrados hacia niveles de gris claros.
- **Uniformidad:** toma valores parecidos para imágenes de regeneración mala como para imágenes de regeneración buena. A simple vista, vemos que la Fig. 15 predomina el gris claro casi blanco, como también sucede en la Fig. 16 donde predomina el color gris oscuro.
- **Entropía:** nos proporciona la misma información que la uniformidad, pero toma valores altos cuando la uniformidad es baja, tal y como se ha explicado en el apartado 2.1.

En el caso de la media y la desviación estándar se puede observar diferencias significativas en los valores que toman para una regeneración buena en comparación con una regeneración mala.

Como se ha podido observar, se cumple lo que se ha explicado anteriormente de manera teórica el apartado 2.1, en referencia a los diferentes momentos del histograma que nos permiten parametrizar el histograma.

3.3. Segundo parámetro de estudio: tamaño histogramas

En este apartado se convertirá el histograma de grises original de 256 niveles de gris en un histograma de 128 y 64 niveles de gris, para ver si nos puede ser útil trabajar con menos niveles de gris. Las imágenes han sido analizadas de nuevo con una máscara circular de radio 350 píxeles. Veamos algunos ejemplos:

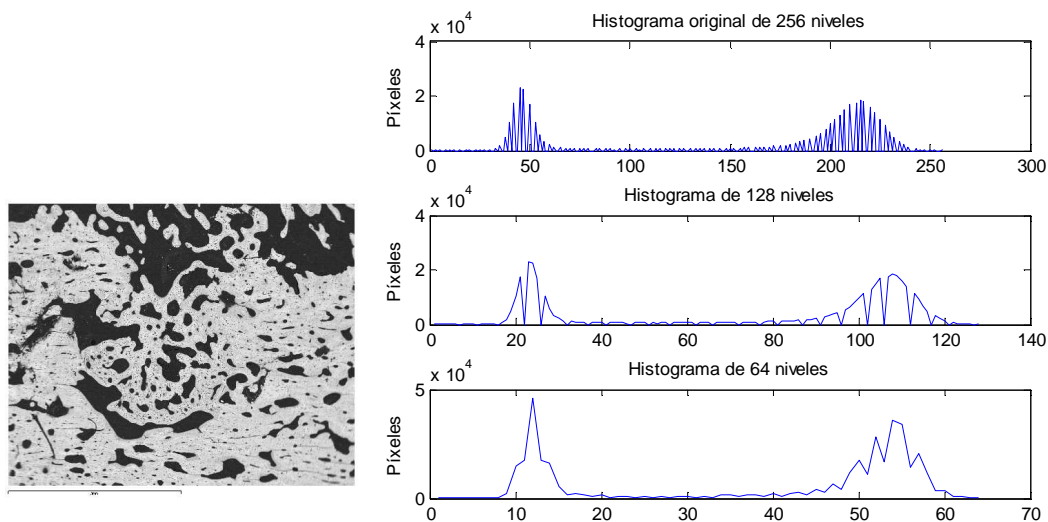


Fig. 17 A la izquierda, ejemplo de regeneración buena, a la derecha, los histogramas de diferentes niveles de gris.

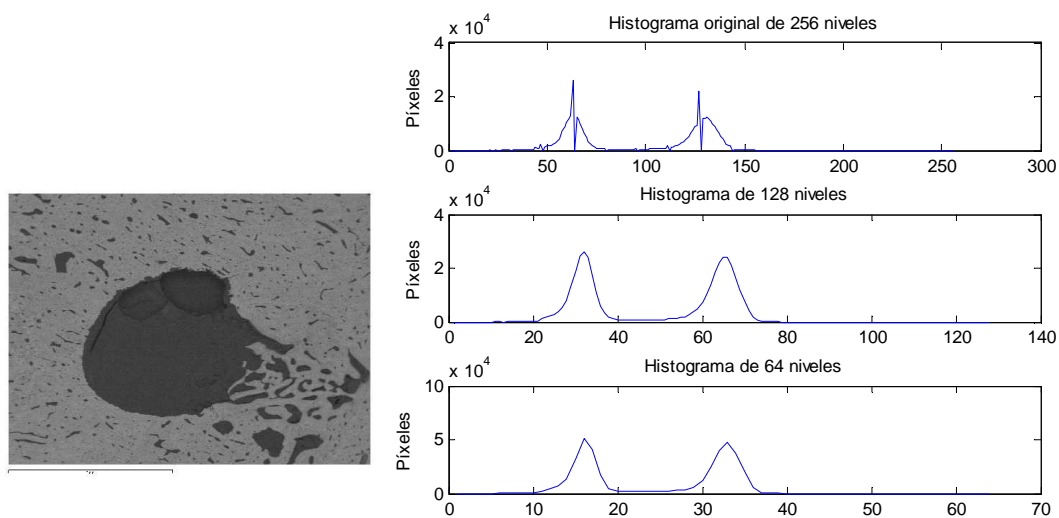


Fig. 18 A la izquierda, ejemplo de regeneración mala, a la derecha, los histogramas de diferentes niveles de gris.

Al convertir el histograma de 256 niveles a 128 o 64 niveles de gris, hace que el histograma se suavice, eliminando algunos sobre picos que se aprecian en los histogramas de 256 niveles de gris, tanto para las imágenes que corresponden a una regeneración buena como a las que corresponden a una regeneración mala.

Estos sobre picos en los histogramas de 256 niveles nos pueden perjudicar a la hora de detectar las modas del histograma, por lo tanto lo mejor será utilizar los histogramas de 128 y 64 niveles para detectar las modas del histograma.

3.4. Tercer parámetro de estudio: tamaño máscara

En este apartado vamos a estudiar cómo influye el tamaño de la máscara en los momentos del histograma.

La elección del radio de la máscara circular dependerá de la región que se quiera analizar, en nuestro caso el objetivo es realizar un análisis representativo de la imagen de manera que al analizar más píxeles obtenemos más muestras que nos describen la imagen. Los posibles niveles de gris que pueden tomar los píxeles de la imagen se tratan como una variable aleatoria, al tener más muestras tenemos más información y podemos conocer mejor como es la imagen. El objetivo es ver si con un radio más pequeño –menos muestras– también podríamos realizar un análisis representativo.

Veamos algunos ejemplos:

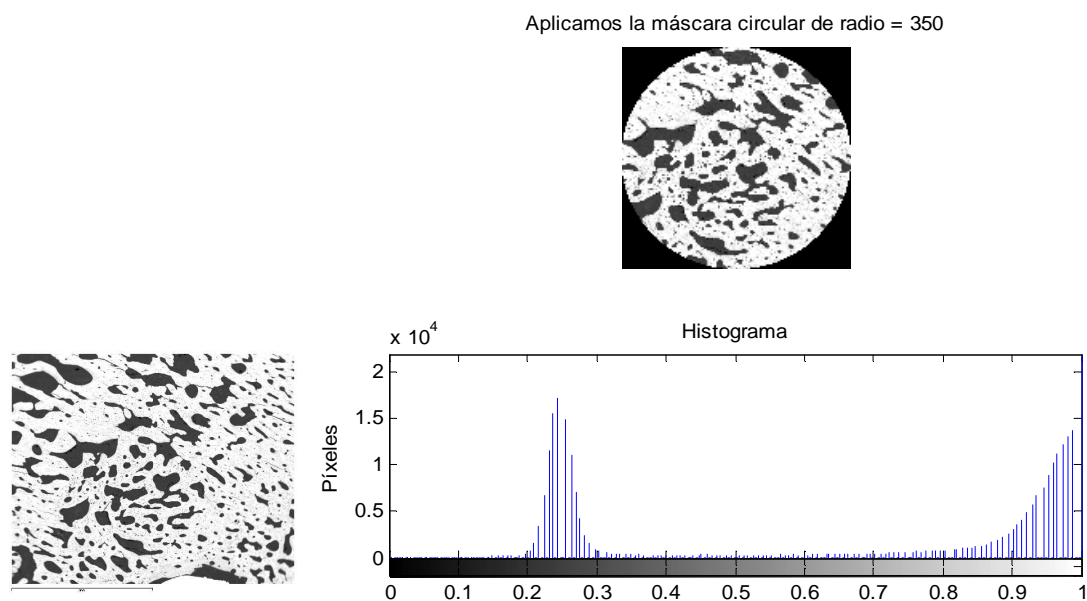


Fig. 19 A la izquierda vemos un ejemplo de regeneración buena, a la derecha arriba se muestra la región que limita la máscara circular, y debajo vemos el histograma de la región que limita la máscara.

Radio máscara	Media	DesvStd	R (norm)	Tercer momento	Uniformidad	Entropía
350	191,27	83,20	0,0962	-7,2751	0,1344	4,5319
300	187,59	84,86	0,0997	-6,8217	0,1302	4,5492
250	181,07	86,87	0,1039	-5,7496	0,1130	4,6649
200	174,60	88,49	0,1074	-4,4673	0,1043	4,7021
150	176,41	88,07	0,1065	-4,8939	0,1023	4,7160
100	169,81	89,45	0,1095	-3,5932	0,0931	4,7838
Vmax-Vmin	21,45	6,25	0,0133	3,6819	0,0413	0,2519

Tabla 5 Evolución de los momentos que nos definen la textura de la Fig. 19 al variar el radio de la máscara. La última fila corresponde a la diferencia entre el valor máximo y mínimo de un mismo parámetro.

Para el caso de la imagen Fig. 19 vemos que al variar el radio de la máscara los parámetros que más varían son la media, la desviación estándar y el tercer momento.

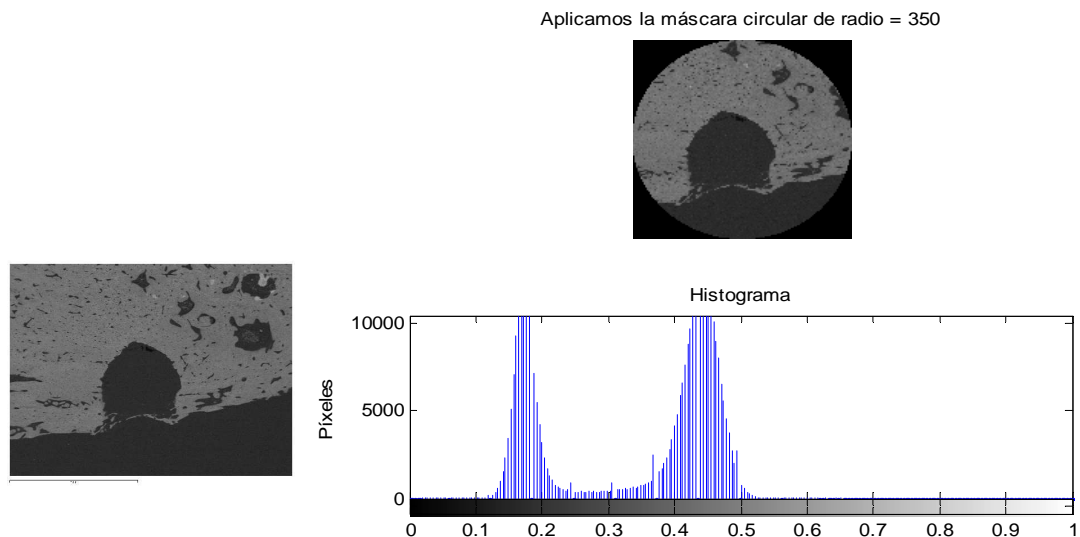


Fig. 20 A la izquierda, ejemplo de regeneración mala, a la derecha arriba se muestra la región que limita la máscara circular, y debajo vemos el histograma de la región que limita la máscara.

Radio máscara	Media	DesvStd	R (norm)	Tercer momento	Uniformidad	Entropía
350	82,12	33,69	0,0171	-0,1105	0,0309	5,5655
300	83,23	33,40	0,0168	-0,1395	0,0300	5,5959
250	82,72	33,62	0,0170	-0,1173	0,0310	5,5578
200	76,07	33,93	0,0174	0,1050	0,0368	5,4313
150	66,39	32,54	0,0160	0,4080	0,0514	5,1271
100	43,81	5,03	0,0003	-0,0010	0,1077	3,7786
Vmax-Vmin	38,30	28,65	0,0167	0,5475	0,0767	1,7869

Tabla 6 Evolución de los momentos que nos definen la textura de la Fig. 20 al variar el radio de la máscara. La última fila corresponde a la diferencia entre el valor máximo y mínimo de un mismo parámetro.

Para el caso de la imagen Fig. 20 volvemos a ver que los parámetros que más varían al disminuir el radio de la máscara, son la media, la desviación estándar y también se puede observar una variación de la entropía que puede ser significativa. Hay que destacar que en esta imagen el tercer momento cambia de signo para un radio de 200 y 150 píxeles.

Para un radio de 350 existe menos uniformidad, y por lo tanto mayor entropía. Para un radio de 100 seleccionamos la zona totalmente homogénea, tal y como se muestra en la Fig. 21:

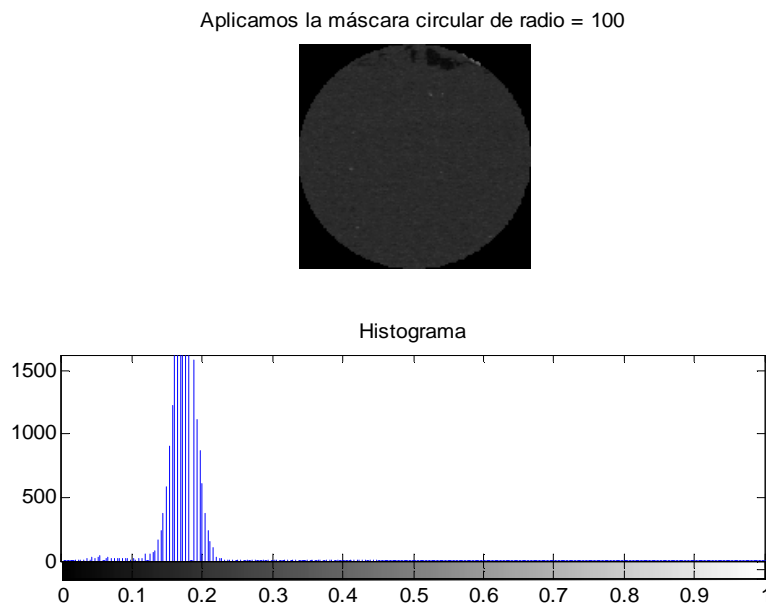


Fig. 21 Resultado de aplicar un radio de 100 píxeles a la Fig. 20.

En este caso existe una mayor uniformidad, pues todos los píxeles tienden a un nivel de gris oscuro y por lo tanto menor incertidumbre, que implica menor entropía.

La elección del radio de la máscara es de gran importancia a la hora de analizar los momentos del histograma, en concreto los valores de la media, que nos indica la intensidad de la imagen, y también los valores de la desviación estándar, que nos indica el contraste, pueden variar de manera significativa según el radio de la máscara que se elija.

La Tabla 7 muestra el número total de píxeles o muestras que son seleccionadas según el radio de la máscara que se escoja y cuantos píxeles son respecto al total de píxeles de la imagen, la cual tiene un zona útil de $1004 \times 753 = 756012$ píxeles como ya se explicó en el apartado 3.1.

<i>Radio máscara</i>	<i>Número de píxeles delimitados por la máscara</i>	<i>Porcentaje respecto al número total de píxeles de la imagen</i>
350	385861	51%
300	283561	37,50%
250	197045	26%
200	126253	16,70%
150	71129	9,50%
100	31689	4,20%

Tabla 7 Resumen de la relación entre los píxeles que seleccionamos según el radio de la máscara que se escoja y que porcentaje representan los píxeles seleccionados respecto al total de píxeles de la imagen.

Utilizando un radio de 350 realizamos un análisis muy representativo de la imagen, pues se selecciona un poco más del 50% de los píxeles de la misma.

Por lo tanto, el tamaño del radio de la máscara óptimo para extraer las medidas de textura es de 350 píxeles. Un radio mayor podría hacer que nos pasáramos de la zona útil de la imagen, recordamos que la zona útil de la imagen es de 753x1004 y el diámetro de la máscara circular con un radio de 350 píxeles es de 700 píxeles.

3.5. Cuarto parámetro de estudio: modas

El valor y posición de las modas son parámetros que nos pueden resultar útiles a la hora de caracterizar el grado de regeneración de una imagen, tal y como se comentó en el apartado 2.1.

Para la detección de las modas, se ha diseñado un detector de picos que localiza los máximos del histograma. El detector de picos se aplicará a todos los histogramas de 256, 128 y 64 niveles de gris.

La moda que está a la derecha nos da información sobre el nivel de gris que posee el tejido óseo en la imagen, pues está más cerca de los niveles claros de gris; la moda que está a la izquierda nos dice el nivel de gris que posee la ausencia de tejido óseo, pues está más cerca de los niveles oscuros de gris. Por lo tanto, nos puede resultar útil definir un umbral entre las dos modas, para poder dividir el histograma en dos zonas, los píxeles que corresponden a tejido óseo y los píxeles que corresponden ausencia de tejido óseo, como veremos más adelante.

También podemos obtener la diferencia de la posición de las modas en el histograma de niveles de gris así como la diferencia del valor entre las dos modas en píxeles.

La Fig. 22 muestra las imágenes que vamos a analizar:




Fig. 22 Imágenes que se analizarán para obtener las modas de sus respectivos histogramas, a la izquierda tenemos un ejemplo de regeneración buena y a la derecha un ejemplo de regeneración mala.




Fig. 23 Histogramas de 256 niveles de gris, con sus respectivas modas, obtenidos de analizar las imágenes de la Fig. 22, el histograma de la izquierda corresponde a la imagen de regeneración buena y el de la derecha a la imagen de regeneración mala.

En la Fig. 23 se produce un error en la detección de las modas en el histograma que corresponde a la imagen de regeneración mala por culpa de los sobre picos.




Fig. 24 Histogramas de 128 niveles de gris, con sus respectivas modas, obtenidos de analizar las imágenes de la Fig. 22, el histograma de la izquierda corresponde a la imagen de regeneración buena y el de la derecha a la imagen de regeneración mala.




Fig. 25 Histogramas de 64 niveles de gris, con sus respectivas modas, obtenidos de analizar las imágenes de la Fig. 22, el histograma de la izquierda corresponde a la imagen de regeneración buena y el de la derecha a la imagen de regeneración mala.

Para el histograma de 256 niveles se produce una detección errónea de la posición de las modas para algunas imágenes. La errónea detección de la posición de las modas, hará que la estimación del umbral sea errónea. Por este motivo lo mejor será no utilizar el histograma de 256 niveles para determinar la posición de las modas.

La posición de la moda izquierda, la cual nos indica el nivel de gris que caracteriza a la ausencia de tejido óseo, apenas varía, mientras que la posición de la moda derecha que caracteriza la presencia de tejido óseo sí varía. Podemos deducir que la posición de la moda derecha está relacionada con el grado de regeneración ósea de la imagen. Por tanto, la posición de las modas es un parámetro que nos será útil a la hora de clasificar una imagen según pertenezca a una regeneración ósea buena o a una regeneración ósea mala. También nos puede ser útil la separación entre las modas, pues cuanto más a la derecha esté la moda derecha, más separación habrá entre las modas, y mejor será el grado de regeneración de la imagen.

Para el caso de las imágenes de regeneración buena, la moda derecha tiende a tomar un valor en píxeles mayor que la moda izquierda y viceversa para el caso de imágenes de regeneración mala. Lo cual también nos será útil a la hora de caracterizar una imagen, aunque la diferencia de valor entre las modas quizás no nos pueda ser tan útil para caracterizar el grado de regeneración ósea, pues puede haber mucha diferencia de valor entre las modas tanto para una imagen de regeneración mala, Fig. 26, como para una imagen de regeneración buena, Fig. 24.

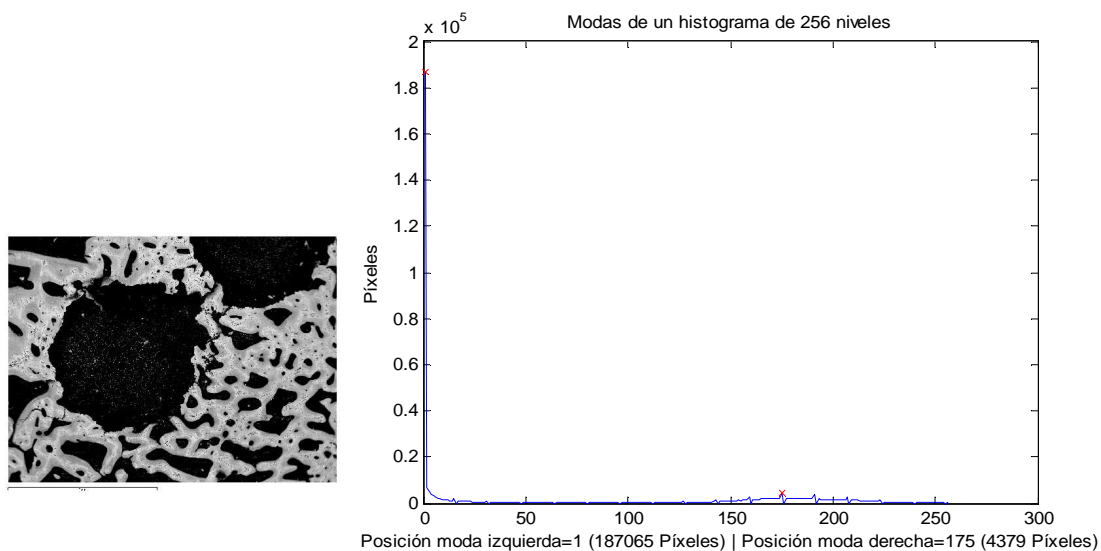


Fig. 26 A la izquierda tenemos un ejemplo de imagen de regeneración mala y a la derecha su respectivo histograma de 256 niveles de gris.

Como se puede observar, en ambas imágenes hay una diferencia de valor de las modas muy grande pero, sin embargo, la Fig. 24 corresponde a una regeneración buena y la Fig. 26 a una regeneración mala.

Otra observación que se ha hecho durante el análisis de las modas de los histogramas de todas las imágenes es que la imagen que muestra la Fig. 27 es la única imagen para la cual obtenemos un error en la detección en las modas en el histograma de 128 niveles.

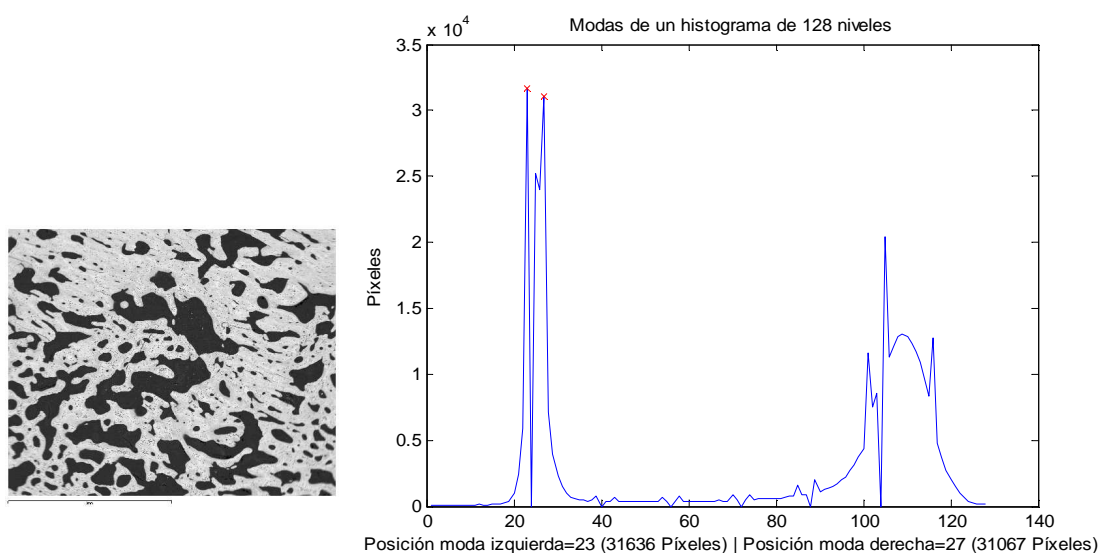


Fig. 27 A la izquierda tenemos un ejemplo de regeneración buena y a la derecha su histograma de 128 niveles.

Por eso es útil en el clasificador que se ha diseñado tener en cuenta los parámetros obtenidos a través del histograma de 64 niveles, como se puede observar en la Tabla 2, pues puede haber un caso en el que los parámetros obtenidos a través del histograma

de 128 niveles de gris sean erróneos y provoquen un error en la clasificación. De manera que al realizar el cálculo de la distancia ésta se verá aumentada por la errónea detección de los parámetros del histograma de 128 niveles de gris pero, sin embargo, la distancia aumentada –debido a los parámetros del histograma de 64 niveles de gris– no será significativa para alejarnos del modelo al cual pertenece la imagen y si servirá para alejarnos del modelo al cual no pertenece la imagen, pues para el histograma de 64 niveles no se ha encontrado ninguna imagen que en la que se produzca un error en la detección de la posición de las modas.

3.6. Quinto parámetro de estudio: distribución de los píxeles

En este apartado se analizará la distribución de los píxeles a banda y banda de un umbral definido por dos criterios con el fin de obtener más información para poder caracterizar las imágenes según su grado de regeneración ósea.

3.6.1. Primer criterio

Una vez se han obtenido las dos modas del histograma, el siguiente paso es estudiar cómo se distribuyen los píxeles en el histograma. Para analizar la distribución será necesario estimar un umbral entre las dos modas tal y como se explicó en el apartado 2.1.

Si miramos la Fig. 8 recordamos que $p_2(z)$ corresponde a niveles de gris claros, presencia de tejido óseo y $p_1(z)$ corresponde a niveles de gris oscuro que corresponden a una ausencia de tejido óseo.

P_1 es la probabilidad de que un píxel tome un valor z , correspondiente a un nivel de gris que pertenece a la ausencia de tejido óseo y P_2 es la probabilidad de que un píxel tome un valor z , correspondiente a un nivel de gris que pertenece presencia de tejido óseo.

Si $P_1=P_2$, entonces el umbral óptimo será:

$$T = \frac{\mu_1 + \mu_2}{2}$$

Donde μ_1 y μ_2 suponemos que corresponde a la posición de la moda izquierda y derecha respectivamente, como podemos observar en la Fig. 8.

Una vez determinado el umbral se pueden obtener el número de píxeles que hay a banda y banda del umbral, pues es un parámetro importante que nos puede resultar útil a la hora de caracterizar el grado de regeneración ósea de una imagen.

Como vimos en el apartado 3.5, trabajar con histogramas de 256 niveles de gris nos puede traer problemas para detectar las modas, por lo que en este apartado sólo se ha trabajado con histogramas de 128 y 64 niveles de gris.

Analizaremos las dos imágenes de la Fig. 5:

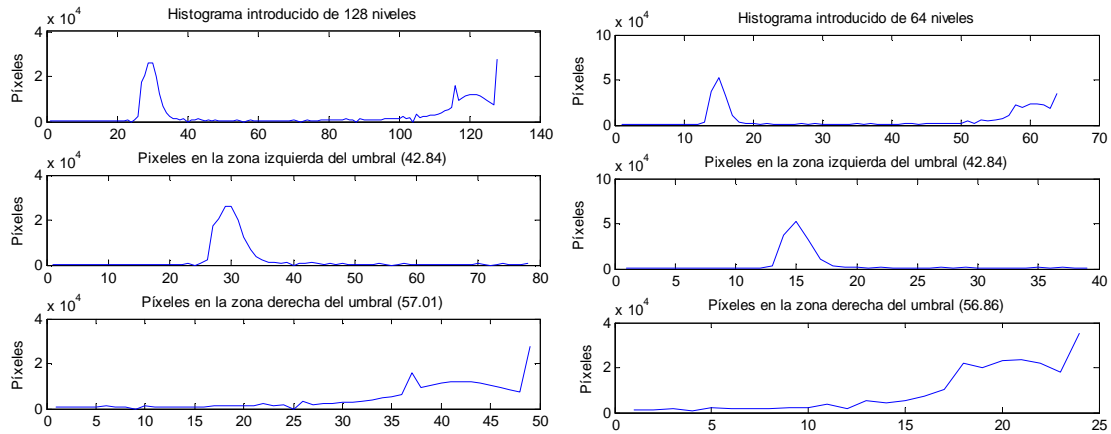


Fig. 28 Estimación del umbral para la imagen de regeneración buena de la Fig. 5, a la izquierda tenemos el caso del histograma de 128 niveles y a la derecha el caso del histograma de 64 niveles. Entre paréntesis podemos observar el porcentaje de píxeles a banda y banda del umbral.

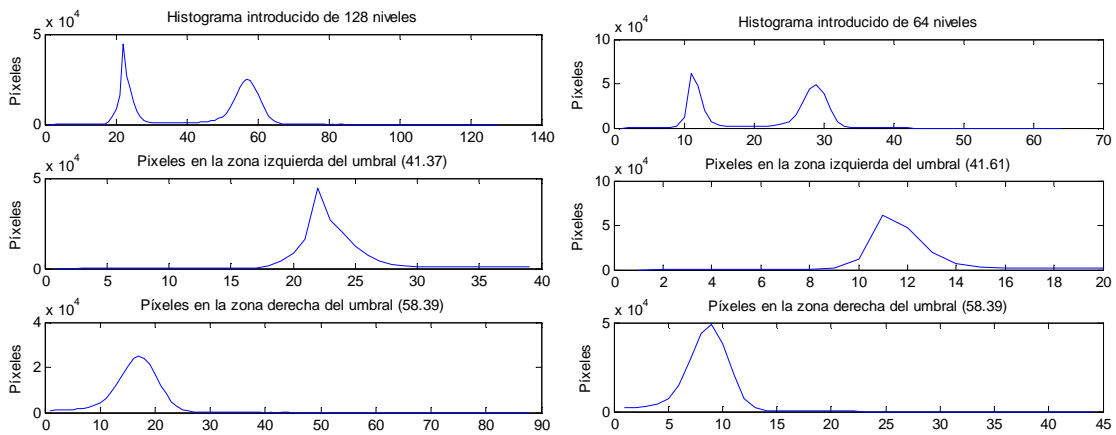


Fig. 29 Estimación del umbral para la imagen de regeneración mala de la Fig. 5, a la izquierda tenemos el caso del histograma de 128 niveles y a la derecha el caso del histograma de 64 niveles. Entre paréntesis podemos observar el porcentaje de píxeles a banda y banda del umbral.

A simple vista resulta difícil caracterizar el grado de regeneración con los porcentajes a banda y banda del umbral, pues en ambos casos Fig. 28 y Fig. 29 los porcentajes son muy parecidos. Una vez creamos los modelos de regeneración buena y mala, veremos si es un parámetro significativo dependiendo del grado de regeneración, es decir, si varía mucho de un modelo al otro o si, por el contrario, apenas varía.

3.6.2. Segundo criterio

El segundo criterio para la estimación del umbral consiste en dividir el histograma justo por la mitad y obtener el número de píxeles que tienden a un nivel de gris claro, presencia de tejido óseo, y los píxeles que tienden a un nivel de gris oscuro, ausencia de tejido óseo.

Para este segundo criterio no importa con qué histograma trabajemos, con el de 256, 128 o 64 niveles de gris, pues no hay que detectar la posición de las modas.

En este apartado también volveremos a trabajar con las imágenes de la Fig. 5:

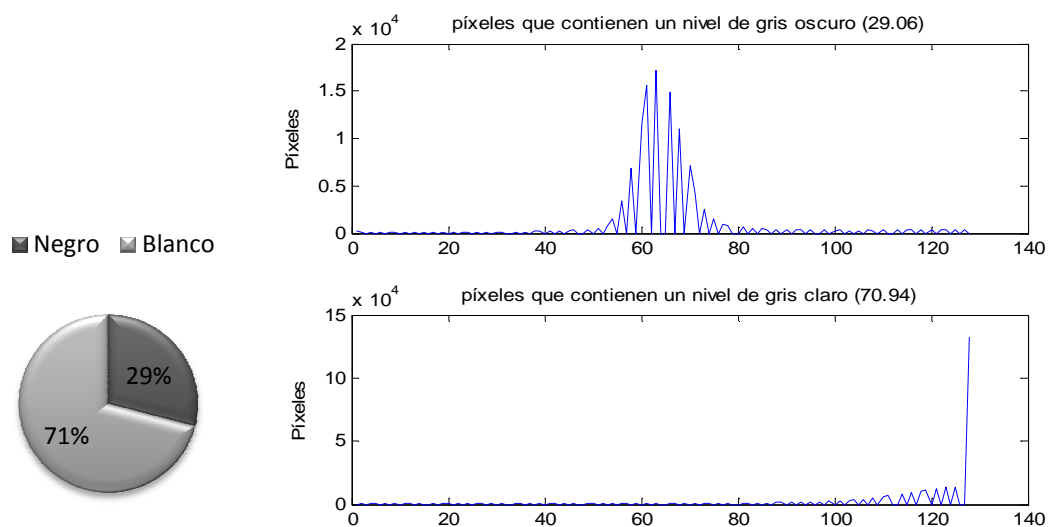


Fig. 30 A la izquierda mostramos un gráfico circular de cómo se distribuyen los píxeles en el caso de la imagen de regeneración buena de la Fig. 5, a la derecha arriba mostramos la mitad izquierda, niveles de gris oscuros del histograma y debajo mostramos la mitad derecha, niveles de gris claros del histograma de 256 niveles.

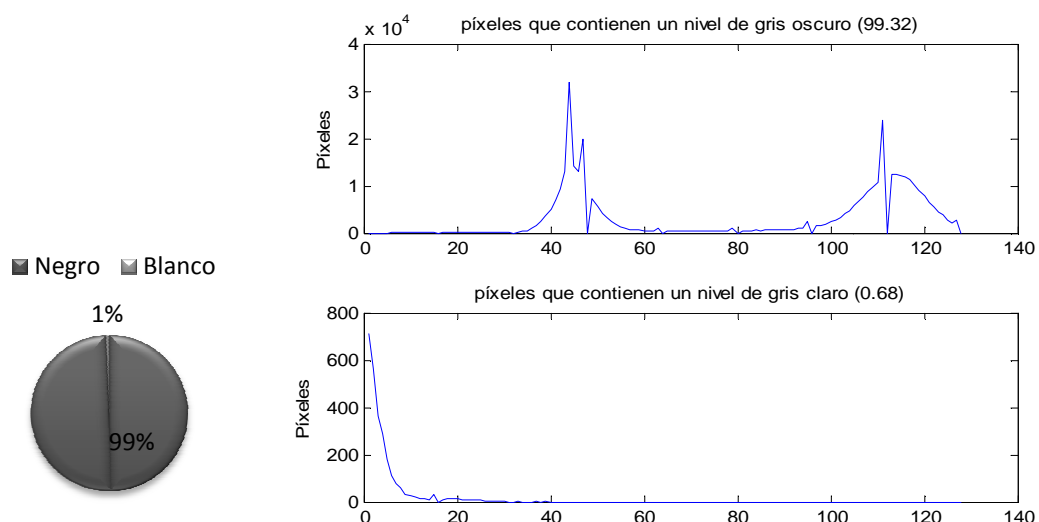


Fig. 31 A la izquierda mostramos un gráfico circular de cómo se distribuyen los píxeles en el caso de la imagen de regeneración mala de la Fig. 5, a la derecha arriba mostramos la mitad izquierda, niveles de gris oscuros del histograma y debajo mostramos la mitad derecha, niveles de gris claros del histograma de 256 niveles.

Como se puede observar existe una clara relación entre los píxeles a banda y banda respecto a la mitad del histograma y el grado de regeneración ósea, sin duda, nos servirá para caracterizar las imágenes según la clase de regeneración ósea a la cual la imagen pertenezca.

3.7. Clasificador de distancia euclídea.

Como ya se introdujo en el apartado 2.2, el clasificador de distancia euclídea se basa en analizar un total de 20 imágenes donde para cada imagen se obtienen 24 parámetros los cuales se muestran en la Tabla 2. Después se agrupan en dos grupos: imágenes de regeneración buena e imágenes de regeneración mala, donde se hace el promedio de los 24 parámetros para obtener un modelo de regeneración buena y un modelo de regeneración mala, como muestran las siguientes tablas:

<i>Modelo Regeneración Mala</i>					
97,51	41,70	0,0292	-0,0955	0,0402	5,8314
21,53	67,46	45,92	11,07	34,07	23
34843,23	23391,30	25952,23	50757,84	45933,84	35251,69
37,27	62,63	37,37	62,42	64,95	35,04

Tabla 8 Modelo de regeneración mala.

<i>Modelo Regeneración Buena</i>					
161,09	75,81	0,0822	-3,5860	0,0493	5,3207
30,6	115,2	84,6	15,16	57	41,83
24345,6	46008,4	25400,8	47268,66	54897,5	30199,83
36,51	63,42	37,07	62,875	36,13	63,86

Tabla 9 Modelo de regeneración buena.

Para que todos los parámetros tengan el mismo peso a la hora de calcular la distancia euclídea calculamos la media y la desviación estándar de todos los parámetros teniendo en cuenta todas las imágenes para así poder normalizar los 24 parámetros. Y el resultado es el siguiente:

<i>Modelo Regeneración Mala</i>					
-0,5831	-0,4857	-0,4883	0,4226	-0,0538	0,3252
-0,2185	-0,5522	-0,4412	-0,2294	-0,6069	-0,4947
0,0701	-0,2334	0,0031	0,0273	-0,1012	0,0340
0,0158	-0,0165	0,0072	-0,0109	0,3741	-0,3741

Tabla 10 Modelo de regeneración mala normalizado.

Modelo Regeneración Buena					
1,2634	1,0524	1,0579	-0,9157	0,1166	-0,7047
0,5682	1,4358	1,1472	0,4970	1,3151	1,0719
-0,1822	0,6070	-0,0082	-0,0591	0,2193	-0,0738
-0,0410	0,0429	-0,0156	0,0236	-0,8105	0,8105

Tabla 11 Modelo de regeneración buena normalizado.

La Tabla 12 muestra la distancia entre los dos modelos para cada parámetro:

Distancia entre los dos modelos					
1,8466	1,5381	1,5463	1,3384	0,1705	1,0299
0,7867	1,9881	1,5885	0,7264	1,9221	1,5667
0,2524	0,8405	0,0113	0,0864	0,3205	0,1079
0,0568	0,0595	0,0229	0,0345	1,1846	1,1846

Tabla 12 Distancia entre los dos modelos de regeneración.

En la Tabla 12 se ha destacado en verde aquellas distancias mayores que la unidad, las cuales nos indican en que dimensiones difieren más los dos modelos y nos son muy útiles para clasificar una imagen. Por lo tanto vemos que es útil utilizar también los datos obtenidos del histograma de 64 niveles pues nos ayudará a aumentar la distancia respecto al modelo al cual la imagen no pertenece y nos ayudará a disminuir la distancia respecto al modelo al cual la imagen pertenece.

Cuando se analiza una imagen para clasificarla, también hay que normalizar los 24 parámetros para después calcular la distancia euclídea con los dos modelos.

3.7.1. Set-up del clasificador de distancia euclídea.

Si se ha supuesto que una imagen pertenece a una clase y el clasificador nos dice que pertenece a otra clase, entonces habrá que volver a la calcular el modelo de la clase en la que se encontraba la imagen sin tener en cuenta la imagen y calcular el modelo al cual no pertenecía la imagen, antes de analizarla con el clasificador, teniendo en cuenta la imagen.

Ejemplo: una imagen que se ha supuesto que es de regeneración buena, el clasificador de distancia euclídea nos dice que es mala. En el caso ejemplificado habrá que volver a calcular el modelo de regeneración mala teniendo en cuenta esta imagen y volver a calcular el modelo de regeneración buena sin tener en cuenta la imagen que se ha analizado.

3.7.2. Análisis de imágenes

A continuación analizaremos con el clasificador las imágenes de la Fig. 32:




Fig. 32 Imágenes que se analizarán con el clasificador, a la izquierda tenemos un ejemplo de regeneración mala y a la derecha un ejemplo de regeneración buena.

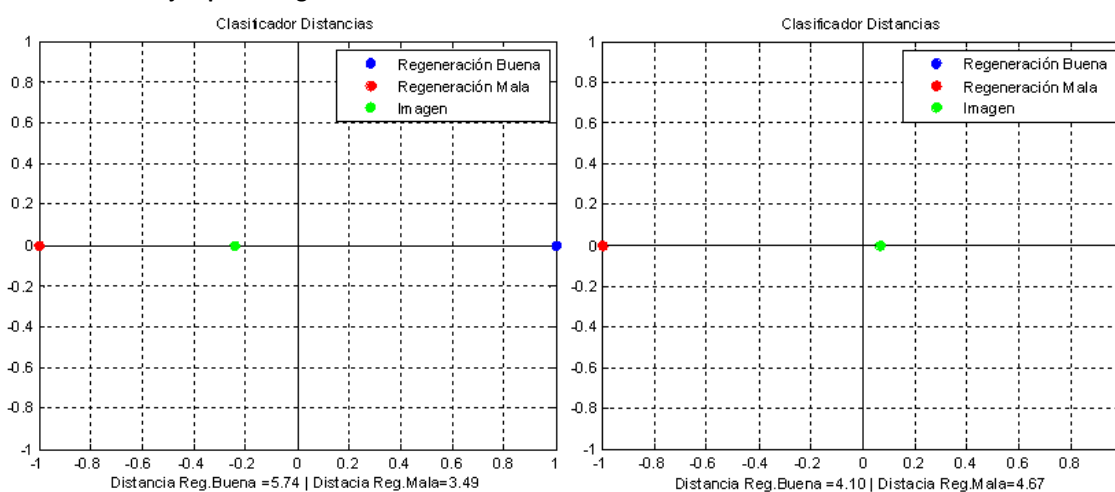


Fig. 33 Resultado de aplicar el clasificador a las imágenes de la Fig. 32, el clasificador de la izquierda corresponde a la imagen de regeneración mala y el clasificador de la derecha a la imagen de regeneración buena de la Fig. 32.

El clasificador de distancia euclídea depende directamente de los modelos de regeneración buena y mala que se calculen. Es muy importante que todas las imágenes a través de las cuales se hayan calculado los modelos pertenezcan a ese modelo.

3.8. Clasificador Bayesiano

Para el clasificador Bayesiano hemos seguido la misma filosofía del clasificador de distancias euclídeas, es decir, se agrupan las imágenes según pertenezcan a una regeneración buena o una regeneración mala y se hace el promedio de sus histogramas de manera que se obtienen dos histogramas: un histograma modelo de regeneración buena y un histograma modelo de regeneración mala. Para cada modelo obtenemos un histograma de 128 y 64 niveles de gris.

La Fig. 34 describe el funcionamiento del clasificador de Bayes:

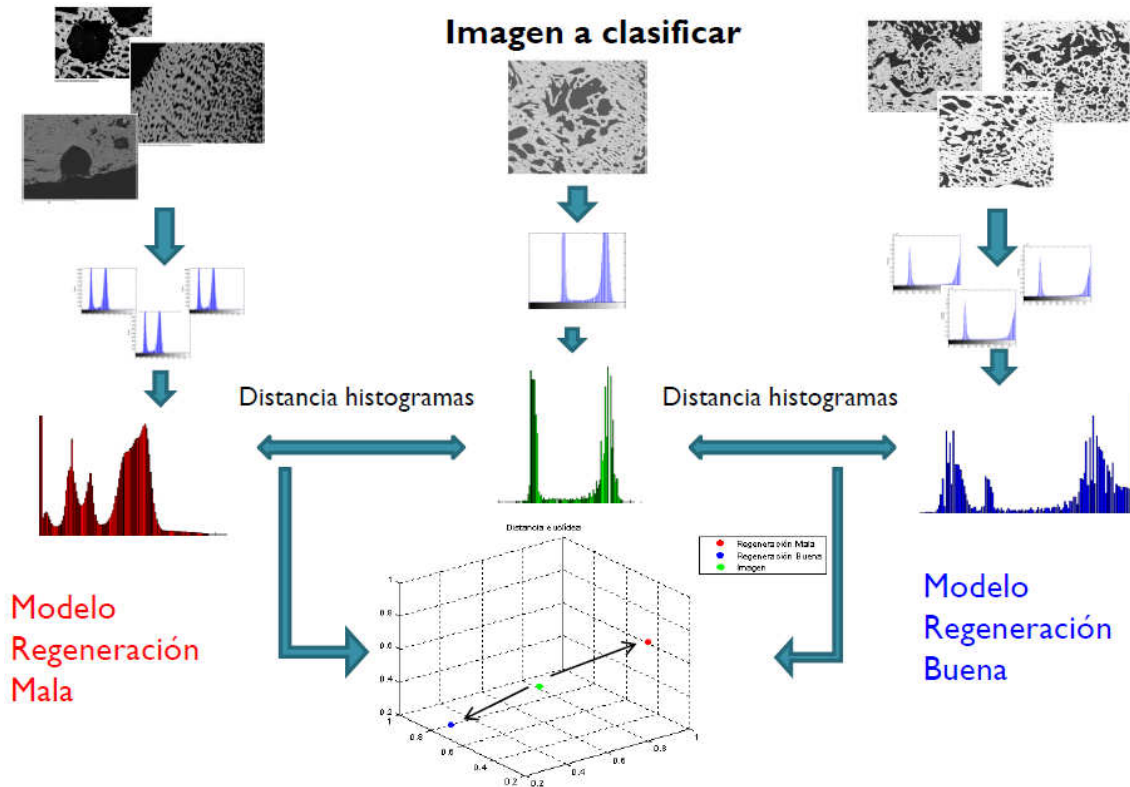


Fig. 34 Clasificador Bayesiano, en la parte inferior de la imagen se vuelve a mostrar un ejemplo en donde hay 3 puntos en un espacio de 3 dimensiones, donde el punto verde corresponde a la imagen que se está analizando y los otros dos puntos a los dos modelos, las flechas simulan la distancia euclídea de la imagen respecto a los dos modelos en un espacio de 3 dimensiones.

Para calcular la distancia entre los histogramas, tanto el histograma de los dos modelos como el de la imagen que se va a clasificar son normalizados respecto a número total de píxeles que contiene cada histograma. La Fig. 35 muestra los dos modelos normalizados:

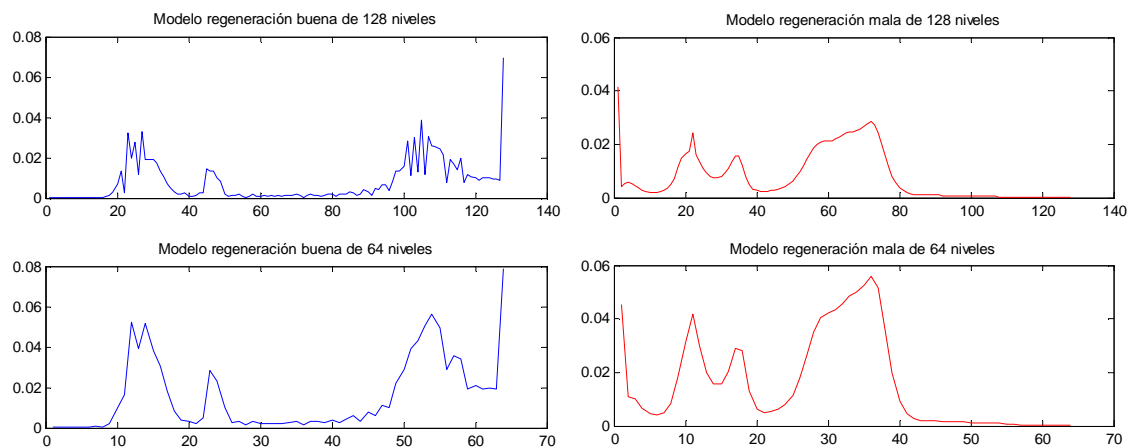


Fig. 35 A la izquierda, histogramas del modelo de regeneración buena, a la derecha, histogramas del modelo de regeneración mala. En la parte superior encontramos los histogramas de 128 niveles y en la parte inferior los de 64 niveles.

3.8.1. Análisis de imágenes

Veamos cual es el resultado de aplicar el clasificador Bayesiano a las imágenes de la Fig. 32:




Fig. 36 Resultado de aplicar el clasificador bayesiano para un histograma de 128 niveles de gris a las imágenes de la Fig. 32, el clasificador de la izquierda corresponde a la imagen de regeneración mala y el clasificador de la derecha a la imagen de regeneración buena de la Fig. 32.

En la Fig. 37 muestra la superposición de los histogramas de las imágenes con los modelos, a simple vista se puede intuir respecto a que modelo la distancia será mínima.

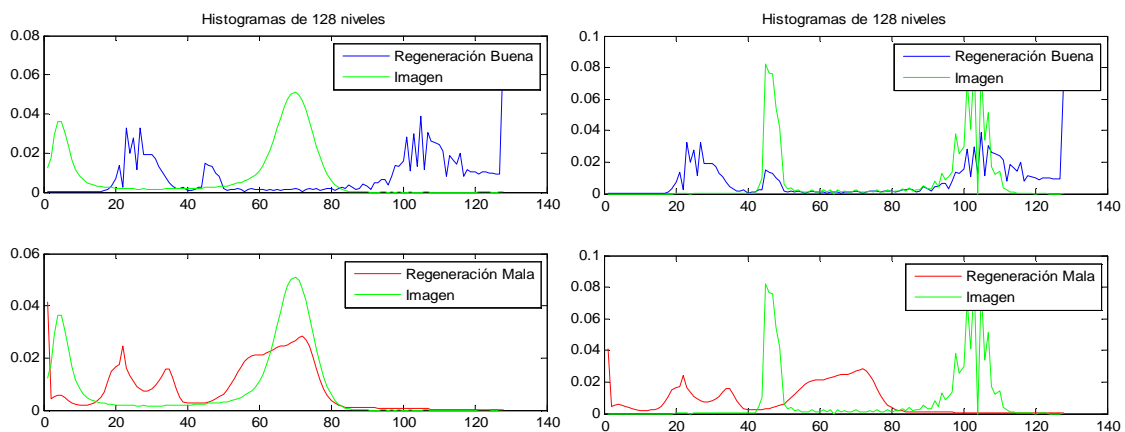


Fig. 37 A la izquierda, vemos la comparación de los modelos respecto al histograma de 128 niveles de gris de la imagen de regeneración mala de la Fig. 32, a la derecha, vemos la comparación de los modelos respecto al histograma de 128 niveles de gris de la imagen de regeneración buena de la Fig. 32.

Los resultados obtenidos calculando la distancia con el histograma de 64 niveles de gris son muy parecidos:




Fig. 38 Resultado de aplicar el clasificador bayesiano para un histograma de 64 niveles de gris a las imágenes de la Fig. 32, el clasificador de la izquierda corresponde a la imagen de regeneración mala y el clasificador de la derecha a la imagen de regeneración buena de la Fig. 32.

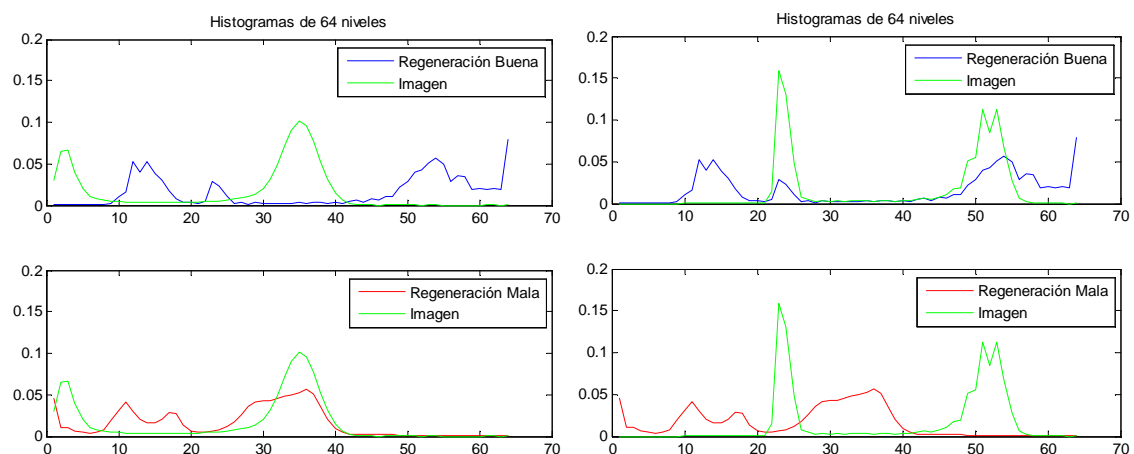


Fig. 39 A la izquierda, vemos la comparación de los modelos respecto al histograma de 64 niveles de gris de la imagen de regeneración mala de la Fig. 32, a la derecha, vemos la comparación de los modelos respecto al histograma de 64 niveles de gris de la imagen de regeneración buena Fig. 32.

3.9. Comparación de los clasificadores

En este apartado se comparará el clasificador bayesiano con el clasificador de distancias euclídeas que se ha diseñado. La siguiente figura muestra el resultado de aplicar ambos clasificadores a las imágenes de la Fig. 32.




Fig. 40 A la izquierda, tenemos el resultado de aplicar el clasificador bayesiano para un histograma de 128 niveles de gris a la imagen de regeneración mala de la Fig. 32, y a la derecha tenemos el resultado de aplicar el clasificador de distancia euclídea a la misma imagen.




Fig. 41 A la izquierda, tenemos el resultado de aplicar el clasificador bayesiano para un histograma de 128 niveles de gris a la imagen de regeneración buena de la Fig. 32, y a la derecha tenemos el resultado de aplicar el clasificador de distancia euclídea a la misma imagen.

Observando la Fig. 40 y Fig. 41 vemos que al calcular la distancia para el caso del clasificador bayesiano nos aleja más del centro, el umbral de decisión. Sin embargo el clasificador de distancias euclídeas, pese a estar más cerca del umbral de decisión no hace una mala clasificación.

Desde el punto de vista de clasificar la imagen ambos clasificadores funcionan bien, excepto en el caso de la imagen de la Fig. 26:




Fig. 42 A la izquierda, tenemos el resultado de aplicar el clasificador bayesiano para un histograma de 128 niveles de gris a la imagen de la Fig. 26, y a la derecha tenemos el resultado de aplicar el clasificador de distancia euclídea a la misma imagen.

Como vemos en la Fig. 42 se produce un error en la clasificación por parte del clasificador bayesiano, mientras que el clasificador de distancia euclídea hace una correcta clasificación.

Utilizar métodos no paramétricos, los cuales trabajan directamente con los datos, es decir, trabajan con todo el histograma como el clasificador de Bayes, nos proporcionan una mayor simplicidad puesto que es un procedimiento más fácil de aprender y de aplicar. Los métodos no paramétricos son útiles con muestras pequeñas donde los datos se tratan con el objetivo de clasificarlos.

Los métodos paramétricos los cuales extraen medidas o parámetros de los datos y nos describen como son éstos, como el clasificador de distancia euclídea, nos permiten extraer mayores conclusiones y no son menos eficientes por usar menos cantidad de datos en sus cálculos en comparación con los métodos no paramétricos.

Viendo los resultados anteriores se puede afirmar que el clasificador bayesiano en comparación con el clasificador de distancia euclídea nos acerca más a los modelos, o lo que es lo mismo, nos distancia más respecto al centro, el umbral de decisión. Esto se debe a que el número de imágenes que se ha analizado no es muy grande, pues si tuviéramos más imágenes podríamos estimar mejores modelos de regeneración buena y mala.

Sin embargo, el clasificador de distancia euclídea nos permite extraer mayores conclusiones, tal y como se muestra en la Tabla 12, donde se puede observar en qué parámetros difieren más las imágenes de regeneración buena y mala.

4. Conclusiones

En este proyecto se ha desarrollado un sistema de evaluación de la regeneración ósea mediante procesamiento de imagen. Expertos de todo el mundo están estudiando materiales capaces de acelerar el proceso de regeneración de tejido óseo. Los materiales de estudio son aplicados en zonas que presentan defectos óseos y después de un determinado periodo de tiempo se extraen imágenes de dichas zonas.

Actualmente la evaluación de la regeneración ósea requiere un experto que mediante la inspección visual de esas imágenes evalúa si el hueso se ha regenerado bien o no, donde la valoración de éste es subjetiva y difícil de cuantificar, pudiendo existir discordancia entre expertos y, además, es posible que tras analizar muchas veces la misma imagen el experto en algún momento cambie su diagnóstico respecto a esa imagen.

Con el fin de aprovechar las imágenes en las que se basa el experto para evaluar la capacidad de regeneración ósea de los materiales de estudio se propone realizar un análisis cuantitativo de la regeneración ósea basado en el procesamiento de imagen mediante el programa Matlab. El algoritmo diseñado es capaz de clasificar imágenes de la mandíbula en: imágenes de regeneración buena y mala a través de parametrizar el histograma de niveles de gris de la imagen.

Para ello se han extraído un total de 24 parámetros de cada histograma. Después de la extracción de los parámetros de un total de 20 imágenes diferentes, éstas se han agrupado en dos grupos: imágenes de regeneración buena e imágenes de regeneración mala. Donde para cada clase de regeneración ósea se hace una media de todos los parámetros que hemos obtenido de cada imagen para obtener dos modelos: un modelo de regeneración buena y modelo de regeneración mala.

El algoritmo de clasificación diseñado se basa en calcular la distancia euclídea entre los parámetros de los modelos y de la imagen que se desea clasificar, donde cada parámetro es considerado una dimensión. Los parámetros de la imagen y de los modelos son normalizados, para que cada parámetro tenga el mismo peso a la hora de calcular la distancia euclídea entre la imagen y los dos modelos.

Si la distancia euclídea es mínima de la imagen respecto al modelo de regeneración buena, significa que la imagen es de regeneración buena y si la distancia es mínima respecto al modelo de regeneración mala significa que la imagen es de regeneración mala.

Basándonos en las pruebas realizadas podemos afirmar que el clasificador diseñado consigue clasificar bien cada una de las imágenes analizadas según si pertenecen a una regeneración buena o a una regeneración mala de manera cuantitativa y en consecuencia nos permite conocer que material de estudio nos proporciona una mejor regeneración ósea. Por tanto, el clasificador elimina la subjetividad que presenta la evaluación tradicional de la regeneración ósea mediante la inspección visual de un experto.

El clasificador diseñado se ha comparado con el conocido clasificador Bayesiano, donde éste último presenta peores prestaciones para algunas imágenes a la hora de realizar la clasificación de las imágenes.

Por otro lado creemos que el clasificador diseñado se podría mejorar analizando más imágenes para estimar mejores modelos de regeneración buena y mala. Además, se podría aprender de los expertos para enseñar al algoritmo cómo hacer una mejor clasificación teniendo en cuenta más parámetros.

A nivel personal la realización de este proyecto ha resultado muy gratificante puesto que nos enfrentábamos a un tema como el procesado de imagen, el cual desconocía. Finalmente se ha conseguido encontrar una solución al problema que se planteaba, del cual no se había hecho nada anteriormente y, además, se han abierto nuevas líneas de investigación para poder seguir mejorando el algoritmo diseñado.

5. Bibliografía

- [1] Digital Image Processing. Rafael C. Gonzalez, 2nd Edition 2002, Prentice Hall, ISBN: 0-201-18075-8.
- [2] Digital Image Processing Using Matlab. Rafael C. Gonzalez, Richard E. Woods, Steven L. Eddins, Prentice Hall, ISBN 0-13-008519-7.
- [3] Mônica Fernandes Gomes, Paula Pinheiro de Abreu, Aline Rose Cantarelli Morosolli, Marcelo Marotta, Araújo, Maria das Graças, Vilela Goulart; Densitometric analysis of the autogenous demineralized dentin matrix on the dental socket wound healing process in humans. Julio del 2006.
- [4] E. Kokkinou, I. Boniatis, L. Costaridou, A. Saridis, E. Panagiotopoulos and G. Panayiotakisa; Monitoring of bone regeneration process by means of texture analysis. University of Patras. Septiembre del 2007.
- [5] Annetta Gadek, Leszek Wojnar, Maicej Tesiorowski and Barbara Jasiewicz; A new method for quantification of regenerated bone tissue on x-ray images of elongated bones. Institute of computing science, Krakow University of Technology. Noviembre del 2003.
- [6] Herve Petite, Veronique Viateau, Wassila Bensaïd, Alain Meunier, Cindy de Pollak, Marianne Bourguignon, Karim Oudina, Laurent Sedel, and Genevieve Guillemin; Tissue-engineered bone regeneration. Université D. Diderot, Faculté de Médecine Lariboisière Saint-Louis. Mayo del 2000.
- [7] Cato T. Laurencin, Frank K. Ko, Mohamed A. Attawia, and Mark D. Borden; Studies on the development of a tissue engineered matrix for bone regeneration. University of Health Sciences, Philadelphia. Octubre del 1997.
- [8] Daniela Bazan, Soh Sato, Gillian Ritman, Luiz Fernando Mota, Raul.G Caffesse; Computer assisted image analysis methods for evaluation of periodontal wound healing. University of Texas, Houston. Junio del 2003.

Resum:

La regeneració òssia és un procés estudiat per experts de tot el món. Aquests experts estudien materials capaços d'accelerar el procés de formació de teixit ossi en zones on s'han produït defectes ossis. Després d'un determinat període de temps de l'aplicació dels materials d'estudi en la zona on hi havia una manca de teixit ossi, s'obtenen imatges d'aquesta zona on l'expert mitjançant l'inspecció visual d'aquestes imatges avalua si l'os s'ha regenerat bé o no. El problema d'aquest mètode d'avaluació és que requereix d'un expert on la valoració d'aquest és subjectiva i difícil de quantificar, el que pot provocar que hi hagi discordança entre experts. Amb la finalitat de aprofitar les imatges en que es basa l'expert per avaluar la capacitat de regeneració òssia dels materials d'estudi es proposa realitzar un anàlisi quantitatiu de la regeneració òssia basat en el processament d'imatge. L'algoritme dissenyat és capaç de classificar imatges de la mandíbula en: imatges de regeneració bona i dolenta mitjançant la parametrització de l'histograma de nivells de grisos de la imatge, solucionant la falta d'objectivitat del mètode d'avaluació de la regeneració òssia i la necessitat d'un expert per realitzar-la.

Resumen:

La regeneración ósea es un proceso estudiado por expertos de todo el mundo. Estos expertos estudian materiales capaces de acelerar el proceso de formación de tejido óseo en zonas donde se han producido defectos óseos. Después de un determinado periodo de tiempo de la aplicación de los materiales de estudio en la zona que carecía de tejido óseo, se obtienen imágenes de dicha zona donde el experto mediante la inspección visual de esas imágenes evalúa si el hueso se ha regenerado bien o no. El problema de este método de evaluación es que requiere un experto y que la valoración de éste es subjetiva y difícil de cuantificar, lo que puede provocar que exista cierta discordancia entre dos expertos. Con el fin de aprovechar las imágenes en las que se basa el experto para evaluar la capacidad de regeneración ósea de los materiales de estudio se propone realizar un análisis cuantitativo de la regeneración ósea basado en el procesado de imagen. El algoritmo diseñado es capaz de clasificar imágenes de la mandíbula en: imágenes de regeneración buena y mala a través de parametrizar el histograma de niveles de gris de la imagen, solventando la falta de objetividad del método de evaluación de la regeneración ósea y la necesidad de un experto para realizarla.

Summary:

Bone regeneration is studied by experts around the world. These experts are studying materials capable to accelerate the bone regeneration in zones where exist bone defects. After a determinate period of time of the material application in those zones, images are obtained from those zones where the experts evaluate the bone regeneration through visual inspection of those images. The problem of this evaluation method is that requires an expert whose evaluation is subjective and it's difficult to quantify, thus other experts can be not agree with this expert. With the purpose to take profit from these images is proposed make a quantitative analysis based on the image processing. The algorithm designed is capable to classify the images from mandible in: good bone regeneration images and bad bone regeneration images, through parameterize the gray level histogram from the images. The algorithm solves the lack of objectivity from the traditional method to evaluate the bone regeneration and the need an expert to make it.

